

Die approbierte Originalversion dieser Diplom-/Masterarbeit ist an der Hauptbibliothek der Technischen Universität Wien aufgestellt (<http://www.ub.tuwien.ac.at>).

The approved original version of this diploma or master thesis is available at the main library of the Vienna University of Technology (<http://www.ub.tuwien.ac.at/englweb/>).



DIPLOMARBEIT

Eine Umwelt Kuznets Kurve für Österreich

Ausgeführt am Institut für
Wirtschaftsmathematik
der Technischen Universität Wien

unter der Anleitung von
a.o. Univ. Prof. Dr. Bernhard Böhm

durch
Ute Schöggel
Feldgasse 4
8682 Hönigsberg

Wien, 3. Dezember 2010

*An dieser Stelle möchte ich Herrn Professor Bernhard Böhm recht herzlich für die
Betreuung meiner Diplomarbeit danken.*

*Meiner Familie, im Speziellen meinen Eltern, danke ich für die Ermöglichung
meines Studiums und die finanzielle Unterstützung.
Besonders bedanken möchte ich mich auch bei meinem Freund, der mich während
meiner gesamten Studienzeit unterstützt hat.*

Kurzfassung

Die Umwelt Kuznets Kurve stellt eine Hypothese über die Verbindung der Umwelt und der Wirtschaft in Form einer inversen U-förmigen Kurve dar.

Diese Arbeit untersucht die Umwelt Kuznets Hypothese für Österreich auf sektoriellem Niveau. Der verwendete Datensatz, die NAMEA Österreich, weist durch ihre Aufteilung in 18 Wirtschaftssektoren für den Zeitraum 1995-2007 eine hohe Heterogenität auf.

Im Vordergrund der Analyse steht die Untersuchung der statistischen Eigenschaften der Daten, welche für eine konsistente Schätzung der Umwelt Kuznets Kurve notwendig sind. Die zentrale Eigenschaft ist die Stationarität der Daten, welche durch die Anwendung zahlreicher Einheitswurzeltests für Paneldaten untersucht wird.

Im Anschluss wird die Umwelt Kuznets Kurve für die fünf Luftschadstoffemissionen Kohlenmonoxid, Kohlendioxid, Schwefeldioxid, Methan und Stickoxid untersucht. Die Bruttowertschöpfung und der Produktionswert pro Erwerbstätigen werden als Regressoren für die Untersuchung der Luftschadstoffemissionen verwendet.

Wie erwartet, zeigt die Analyse der NAMEA Österreich die Existenz der Umwelt Kuznets Kurve für einige Luftschadstoffemissionen. Kohlendioxid und Schwefeldioxid folgen einem inversen U-förmigen Verlauf. Die Analyse der Teilbereiche der Wirtschaft, Landwirtschaft, Industrie inkl. Bauwirtschaft und Dienstleistung, zeigt, dass die Entwicklung der gesamten produzierenden Sektoren vor allem durch den Industriesektor dominiert wird.

Inhaltsverzeichnis

1	Einleitung	1
2	Einführung in die Umwelt Kuznets Kurve	3
3	NAMEA Österreich	10
4	Modelle für Paneldaten	16
4.1	Pooling	17
4.2	Das „Random Effects“ Modell	17
4.3	Das „Fixed Effects“ Modell	19
4.4	Vergleich des „Random und Fixed Effects“ Modells	21
4.5	Die ökonometrische Kritik der EKC Kurve	23
5	Tests auf Einheitswurzeln	26
5.1	Allgemeine Theorie	26
5.2	Einheitswurzeltests der ersten Generation	29
5.2.1	Der Test von Levin, Lin und Chu (2002)	29
5.2.2	Der Test von Im, Pesaran und Shin (2003)	31
5.2.3	Das Fisher Test Prinzip	32
5.2.4	Vergleich der Tests	34
5.2.5	Die NAMEA Testergebnisse	36
5.3	Einheitswurzeltests der zweiten Generation - Der Faktoren Ansatz	38
5.3.1	Die Informationskriterien	40
5.3.2	Das Testprinzip von Moon und Perron (2004) und Phillips und Sul (2003)	42
5.3.3	Die Tests von Bai und Ng (2004)	46
5.3.4	Der Test von Pesaran (2007)	49
5.3.5	Der Test von Choi (2002)	51
5.3.6	Vergleich der Tests	53
5.3.7	Die NAMEA Testergebnisse	54
5.4	Zweite Generation der Einheitswurzeltests - Weitere Ansätze zur Behandlung der Querschnittsabhängigkeiten	58
5.4.1	Der Test von Chang (2002)	58
5.4.2	Der Test von Shin und Kang (2006)	60

5.4.3	Der Test von Lopez (2009)	62
5.4.4	Der Test von Jönsson (2005)	63
5.4.5	Der Test von Breitung und Das (2005)	64
5.4.6	Vergleich der Tests	66
5.4.7	Die NAMEA Testergebnisse	67
5.5	Folgerungen aus den Ergebnissen der Einheitswurzeltests	68
6	Schätzung der Umwelt Kuznets Kurve für Österreich	72
6.1	Die NAMEA Testergebnisse	78
6.1.1	Alle produzierenden Sektoren	78
6.1.2	Landwirtschaft	83
6.1.3	Industrie inklusive Bauwirtschaft	85
6.1.4	Dienstleistung	85
6.1.5	Ein Vergleich mit Italien	90
7	Schlussbemerkungen	92
	Appendix	96
A	Die Programmiercodes	96
A.1	Die Codes für die Einheitswurzeltests	96
A.1.1	Der Test von Levin, Lin und Chu (2002)	97
A.1.2	Der Test von Im, Pesaran und Shin (2003)	107
A.1.3	Die Fisher Tests	111
A.1.4	Der Test von Pesaran (2007)	112
A.1.5	Der Test von Choi (2002)	115
A.1.6	Die Informationskriterien	118
A.1.7	Der Test von Bai und Ng (2004)	124
A.1.8	Der Test von Breitung und Das (2005)	127
A.1.9	Der Test von Jönsen (2005)	133
A.1.10	Der Test von Chang (2002)	137
A.2	Die Programmiercodes für die Paneldatenmodelle	144
B	Der Inhalt der CD	146
	Literaturverzeichnis	148

Kapitel 1

Einleitung

Der Zusammenhang zwischen der Wirtschaft und der Umwelt spielt heute eine tragende Rolle. Verbesserungen der Umweltindikatoren in Bezug auf die Wirtschaftsindikatoren werden häufig verwendet, um den Fortschritt bei der Verwendung natürlicher Ressourcen zu erklären. Die Umwelt Kuznets Kurve beschreibt den Zusammenhang der wirtschaftlichen Entwicklung und dem Grad der Umweltverschmutzung durch eine inverse U-förmige Kurve. Das bedeutet, dass der Umweltindikator zunächst mit dem Wirtschaftsindikator ansteigt, dann stagniert und schließlich mit steigendem Wirtschaftsindikator abfällt. Seit ihrer Entdeckung 1992 ist das Konzept sehr beliebt um die Entwicklung diverser Umweltschäden durch die wirtschaftliche Entwicklung zu erklären.

Die Fragestellung der Umwelt Kuznets Kurve wird in dieser Arbeit für Österreich auf sektoriellem Niveau für fünf Luftschadstoffemissionen untersucht. Die Analyse der Umwelt Kuznets Kurve wird kritisch betrachtet und die statistischen Eigenschaften der verwendeten Daten werden hinterfragt. Der verwendete Paneldatensatz besitzt durch die Aufteilung in 18 Wirtschaftssektoren für die Jahre 1995-2007 eine hohe Heterogenität. Die Verwendung derartiger Daten zur Analyse der Umwelt Kuznets Kurve ist sehr selten und soll tiefere Einblicke in das Verständnis des Wirtschaft-Umwelt Verhältnisses geben.

Bevor eine Schätzung der Kurve durchgeführt werden kann, müssen die statistischen Eigenschaften der Daten geklärt werden. Die zentrale Eigenschaft ist die Stationarität der Daten, da die Schätzungen der Umwelt Kuznets Kurve bei Zutreffen der Nicht-Stationarität ihre Gültigkeit verlieren. Der Datensatz erfordert aber auch die Prüfung anderer statistischer Eigenschaften, wie serielle Korrelation und Heteroskedastizität der Zeitreihen.

Die Arbeit ist wie folgend gegliedert. Das Kapitel 2 führt in die Umwelt Kuznets Kurve ein. Im Kapitel 3 wird der verwendete Datensatz, die NAMEA Österreich, präsentiert. Die Schätzmethoden für Paneldaten werden in Kapitel 4 erläutert. Das Kapitel 5 gibt einen Überblick über die Entwicklungen der Einheitswurzeltests für Paneldaten. Die präsentierten Teststatistiken werden auf den Datensatz der NAMEA Österreich angewendet. Im Kapitel 6 wird die Umwelt Kuznets Kurve auf sektoriellem Niveau für Österreich geschätzt. Das Kapitel 7 stellt eine Zusammenfassung der Arbeit dar.

Die numerische Umsetzung dieser Arbeit wurde mit Hilfe des Statistikprogramms Gretl durchgeführt. Gretl ist eine frei verfügbare Software, welche hauptsächlich für ökonomische Anwendungen benutzt wird. Sie kann von <http://gretl.sourceforge.net/> heruntergeladen werden.

Kapitel 2

Einführung in die Umwelt Kuznets Kurve

Die Umwelt Kuznets Kurve („Environmental Kuznets Curve“ (EKC)) stellt eine Hypothese über den Zusammenhang des Grads der Umweltverschmutzung und der ökonomischen Entwicklung eines Landes, häufig durch das Bruttoinlandsprodukt (BIP) gemessen, dar.

Generell beginnt wirtschaftliches Wachstum mit der Intensivierung der Landwirtschaft und der Ausbeutung anderer Ressourcen. Ab einem gewissen Punkt ist der Verbrauch größer als die Regeneration der Ressourcen und die Abfallproduktion steigt an. Die Umweltbelastung steigt in diesem Stadium der Wirtschaftsentwicklung mit Zunahme der Wirtschaftsaktivitäten an. Auf einem höheren Niveau der wirtschaftlichen Entwicklung findet ein Wechsel zu informationsintensiven Industrien zusammen mit einem höheren Wissensstand an Umweltbewusstsein statt. Daraus resultieren eine bessere Technologie in der Produktion und erhöhte Ausgaben für den Umweltschutz. Infolge kommt es zu Einschränkungen der Umweltbelastungen und der Umweltindikator nimmt mit wachsender wirtschaftlicher Entwicklung ab. Anders ausgedrückt nimmt die Umweltbelastung zunächst proportional stärker zu als das pro Kopf BIP, ab einem gewissen Punkt, dem Wendepunkt, verringert sich die Umweltbelastung in Bezug auf das Wachstum des pro Kopf BIPs. Die EKC Hypothese beschreibt daher den systematischen Zusammenhang des Umwelt-Einkommensverhältnisses durch eine inverse U-förmige Kurve.

Die EKC ist nach Kuznets (1955) benannt, der sich mit dem Verhältnis der Einkommensaufteilung und der wirtschaftlichen Entwicklung beschäftigte. Er stellte

die Hypothese auf, dass die ungerechte Einkommensaufteilung zuerst ansteigt und mit steigendem pro Kopf BIP zurückgeht.

Der Zusammenhang zwischen Umweltindikatoren und Wirtschaftsentwicklung wurde 1991 zum ersten Mal von Grossman und Krueger (1991) definiert, welche sich mit einer Studie der Umwelteinflüsse der NAFTA beschäftigten. Popularisiert wurde das EKC Konzept 1992 durch den „1992 World Bank Development Report“, welcher auf einer Studie von Shafik und Bandyopadhyay (1992) beruht. Panayotou (1993) nannte das Konzept 1993 zum ersten Mal Umwelt Kuznets Kurve. Seitdem wurden zahlreiche Studien für diverse umweltbelastende Indikatoren publiziert.

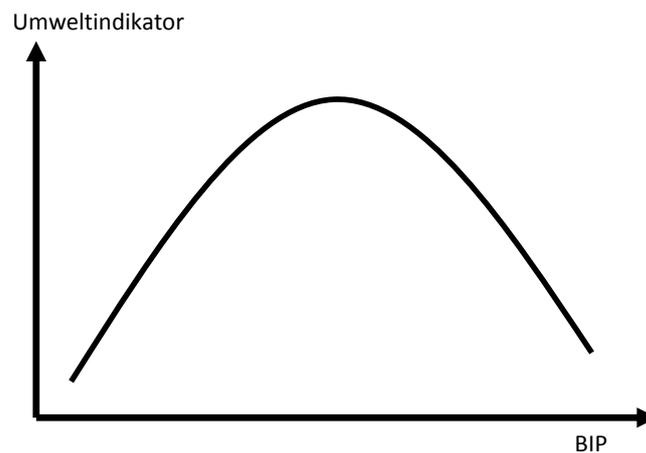


Abbildung 2.1: Der Verlauf der EKC Kurve

Verschiedene ökonomische Faktoren sprechen für die Existenz einer EKC Kurve. Produktion beeinflusst die Umweltqualität durch drei Effekte, den Skaleneffekt, den technologischen Effekt und den Kompositionseffekt. Der Skaleneffekt beschreibt die Abhängigkeit des Outputs von den eingesetzten Ressourcen. Die Outputmenge kann proportional stärker, gleich oder schwächer steigen, wenn alle Inputs um einen bestimmten Faktor erhöht werden. Man spricht von konstanten Skaleneffekten, wenn bei Erhöhung des Inputs um einen bestimmten Faktor der

Output mit demselben Faktor steigt. Daher wächst laut konstanten Skaleneffekten der Verschmutzungsgrad der Umwelt mit dem gleichen Prozentsatz wie die Wirtschaft an. Der Skaleneffekt hat einen negativen Einfluss auf die Umweltbelastung. Der Kompositionseffekt beschreibt den Zusammenhang des Wirtschaftswachstums mit der Veränderung der Struktur einer Wirtschaft im Laufe der Entwicklung. Der Technologieeffekt besagt, dass die Ausgaben für Forschung mit zunehmenden Einkommen steigen. Eine reichere Wirtschaft gibt mehr Geld für Forschung aus und die technologische Entwicklung schreitet schneller voran. Der technologische Fortschritt resultiert in der Ersetzung „schmutziger“ durch „saubere“ Technologien und in Effizienzgewinnen bei der Produktion. Das bedeutet, dass für den gleichen Output weniger Ressourcen benötigt werden. Der Technologieeffekt und der Kompositionseffekt haben daher einen positiven Einfluss auf die Umweltqualität.

Außerdem spricht die Einkommenselastizität der Nachfrage nach Umweltqualität für die Existenz einer EKC Kurve. Arme Länder beachten die Umweltqualität kaum oder gar nicht. Steigt das Einkommen, steigt auch die Nachfrage nach einer sauberen Umwelt. Laut Roca (2003) wächst das Bewusstsein in eine saubere Umwelt zu investieren proportional stärker an als das Einkommen. Umweltqualität ist sozusagen ein Luxusgut, welches durch Erziehung und Bewusstsein an Wert gewinnt. Menschen mit einem höheren Einkommen bewerten die Erhaltung einer sauberen Umwelt höher und geben daher mehr Geld für „grüne“ Konsumgüter aus. Außerdem erhöhen sie den Druck für Regulationen der Wirtschaft durch die Politik und die Ausgaben für Umweltschutz.

Der internationale Handel trägt bedeutend zur Erklärung der EKC bei. Handel führt zu einer Vergrößerung der Wirtschaft und so zu mehr Umweltverschmutzung. Gleichzeitig steigert der Handel aber die Motivation die Umwelt zu schützen. Im Zusammenhang mit Handel existieren zwei Hypothesen für die EKC: die „Pollution Haven Hypothesis“ und die „Displacement Hypothesis“. Wenn sich die Produktion eines Landes ändert, bleibt die Struktur des Konsums gleich. Folglich führt offener Handel laut der „Displacement Hypothesis“ zu einer Ausgliederung von verschmutzungsintensiven Industrien in ärmere Länder, da die Industrienationen strengere Umweltvorschriften haben. Die „Pollution Haven Hypothesis“ bildet das positive Gegenstück und besagt, dass Handel das Einkommensniveau der Menschen in Entwicklungsländern anhebt und so deren Umweltbewusstsein steigert.

Es gibt verschiedene Theorien für die theoretische Existenz der EKC. Die empirischen Studien sind mengenmäßig stärker vertreten. Die theoretischen Studien versuchen die Existenz der EKC in Modellen durch politische und technologische Faktoren zu erklären. Für einen ausführlichen Überblick über diese Studien wird auf Kijima, Nishide und Ohyama (2010) verwiesen.

Die Idee der EKC kann laut Dinda (2004) „*durch den Prozess der wirtschaftlichen Entwicklung von einer sauberen landwirtschaftlichen Wirtschaft zu einer verschmutzenden Industrie und schlussendlich zu einer sauberen Dienstleistungswirtschaft*“ (Dinda (2004), Seite 434) erklärt werden und beschreibt daher die langfristige Entwicklung einer Wirtschaft.

Empirische Rückschlüsse für die Existenz einer EKC wurden in vielen Studien gefunden. Ein Großteil dieser Studien verwendet für die umweltbezogenen Daten die Datensätze der World Resources und der OECD und für die ökonomischen Daten die Statistiken des Penn World Table und der World Bank. Es handelt sich daher meistens um Paneldaten. Paneldaten sind wiederholte Beobachtungen derselben Menge an Querschnittseinheiten, wobei für jede Querschnittseinheit zu einem bestimmten Zeitpunkt eine Messung durchgeführt wird und so eine Zeitreihe für jede Querschnittseinheit entsteht.

Ein Modell der EKC für Paneldaten kann durch die folgende Gleichung beschrieben werden:

$$\ln(U_{it}) = \alpha_i + \gamma_t + \beta_1 \ln\left(\frac{X_{it}}{P_{it}}\right) + \beta_2 \ln\left(\frac{X_{it}}{P_{it}}\right)^2 + \beta_3 \ln\left(\frac{X_{it}}{P_{it}}\right)^3 + \varepsilon_{it}, \quad (2.1)$$

wobei U_{it} den umweltbezogenen Indikator bezeichnet und X_{it} die wirtschaftliche Komponente, welche durch die Population P_{it} dividiert wird. Häufig wird als erklärende Variable das pro Kopf BIP verwendet. Der Laufparameter i beschreibt die Querschnittseinheit, wie beispielsweise ein Land oder eine Region. Üblicherweise gilt $i = 1, \dots, N$. t steht für die Zeitperiode, $t = 1, \dots, T$. α_i stellen die querschnittsspezifischen Konstanten dar, welche über die einzelnen Querschnittseinheiten variieren können. γ_t stellen die periodenspezifischen Konstanten dar, sie sind für jede Querschnittseinheit gleich und können sich für jede betrachtete Periode ändern. Als Alternative zu den periodenspezifischen Konstanten können lineare Zeittrends γ_{it} betrachtet werden. ε_{it} bezeichnet die stochastischen Schocks.

Es wird der Logarithmus (ln) der Daten verwendet, da es auf Basis der Datengrundlage nicht sinnvoll ist, wenn die Variablen negative Werte annehmen können. Die

Umweltverschmutzung kann nicht mehr als „sauber“ sein.

Das Modell (2.1) misst den absoluten Zusammenhang zwischen dem Umweltindikator und dem pro Kopf BIP. Eine weitere Möglichkeit ist die Messung des Umweltindikators pro Kopf, man spricht in diesem Fall von der relativen Messung. Alternativ kann der Umweltindikator durch das BIP dividiert werden, um eine Messung pro Produktionseinheit zu erhalten.

Die absolute Messung ist für Umweltindikatoren sinnvoll bei denen das Volumen des Schadstoffs relevant ist. Ein Beispiel dafür ist die Verschmutzung eines Gewässers. Ab einer gewissen Schadstoffmenge können die Fische im Wasser nicht mehr überleben.

Eine relative Messung des Umweltindikators sollte durchgeführt werden, wenn die pro Kopf Umweltverschmutzung von Interesse ist. Die Messung der Niveaus ist beispielsweise für den Abfallstoff sinnvoll, da die Abfallmenge, welche eine einzelne Person in einem gewissen Zeitraum produziert, interessant ist.

Die produktionsorientierte Messung sollte verwendet werden, wenn der Umweltindikator durch die Produktion gesteuert wird. Ein Beispiel dafür ist die Verschmutzung des Bodens durch Düngemittel in der Landwirtschaft.

Durch das Modell können folgende Zusammenhänge zwischen der Wirtschaft und der Umweltbelastung beschrieben werden:

- Für $\beta_1 = 0, \beta_2 = 0, \beta_3 = 0$ existiert kein Zusammenhang zwischen Wirtschaft und Umwelt, der durch die Gleichung erklärt wird.
- Für $\beta_1 > 0, \beta_2 = 0, \beta_3 = 0$ gibt es einen monoton steigenden Zusammenhang.
- Für $\beta_1 < 0, \beta_2 = 0, \beta_3 = 0$ besteht eine monoton fallende Verbindung.
- Die EKC Kurve existiert für $\beta_1 > 0, \beta_2 < 0, \beta_3 = 0$.
- Für $\beta_1 < 0, \beta_2 > 0, \beta_3 = 0$ gibt es einen U-förmigen Zusammenhang.
- Für $\beta_1 > 0, \beta_2 < 0, \beta_3 > 0$ existiert ein kubisches Polynom, welches durch eine N-förmige Kurve beschrieben werden kann.
- Für $\beta_1 < 0, \beta_2 > 0, \beta_3 < 0$ ist der Verlauf gegenläufig zur N-förmigen Kurve.

Die EKC Kurve ist daher nur ein mögliches Modell für die Beziehung von Umwelt und Wirtschaft. Trifft die EKC Hypothese zu, kann der Wendepunkt (WP) berechnet werden: $WP = e^{-\frac{\beta_1}{2\beta_2}}$.

Auch der N-förmige Kurvenverlauf beschreibt in einem gewissen Sinn die EKC Relation: Die Konzentration des Umweltindikators steigt mit wachsender Produktion an bis der erste Wendepunkt erreicht wird, danach fällt sie mit steigender Produktion ab bis der zweite Wendepunkt überschritten wird. Ab diesem kommt es zu einer erneuten Koppelung des Umweltindikators und der Produktion. Der Grad der Umweltverschmutzung steigt mit zusätzlicher Produktion wieder an.

Laut Galeotti, Manera und Lanza (2006) kann die Literatur der EKC Kurve in zwei Phasen unterteilt werden. „Die erste Phase kann als die enthusiastische Phase der EKC Geschichte beschrieben werden in der die EKC Kurve als gegeben angenommen wurde.“ (Galeotti, Manera und Lanza (2006), Seite 552) Die Studien konzentrierten sich in dieser Phase auf das Überprüfen der EKC Hypothese basierend auf Makro-Paneldaten für diverse Umweltindikatoren, wie verschiedene Luftschadstoffemissionen, den Sauerstoffgehalt und den Verschmutzungsgrad von Gewässern, den Abfall oder die Abholzung, und die Berechnung der Kurvenverläufe und deren Wendepunkte.

Die wesentlichen Ergebnisse dieser empirischen Studien für die Luftschadstoffemissionen zeigen, dass vor allem für lokale Luftverschmutzer, wie Schwefeldioxid, die EKC Hypothese zutrifft. Kohlendioxid und andere globale Luftschadstoffemissionen wachsen mit dem Einkommen monoton an oder fallen mit diesem monoton. Sie zeigen daher keine Hinweise für die Existenz der EKC.

In der zweiten Phase kam die Ernüchterung: „Die Robustheit der EKC Hypothese wurde in Frage gestellt.“ (Galeotti, Manera und Lanza (2006), Seite 553)

Verschiedene ökonomische Kritikpunkte an der EKC treten auf. Arrow und andere (1995) kritisieren vor allem, dass in der EKC das pro Kopf BIP als exogene Variable modelliert wird. Die Belastung der Umwelt durch die Produktion ist daher nicht so gravierend, um die ökonomische Produktion direkt zu beeinflussen.

Stern, Common und Barbier (1996), sowie Arrow und andere (1995) behaupten, dass die EKC in gewissen Punkten auf den Handel zurückzuführen ist. Industrieländer gliedern die Produktion in Länder mit niedrigen pro Kopf BIPs aus, um Kosten zu sparen. Die benötigten in der Produktion umweltbelastenden Güter werden aus dem Ausland importiert.

Im Laufe der Entwicklung sind einige Schadstoffemissionen zurückgegangen. Dieser Rückgang wurde häufig durch Veränderungen der Technologie und verstärkte Umweltregulationen für diese Schadstoffe erzielt. Diese Regulationen verursachen meist die Änderung des Inputmixes und führen nur in den seltensten Fällen zu Ef-

fizienzgewinnen in der Produktion. Die Reduktion einer Schadstoffemission führt daher oft zur Erhöhung anderer, neuer Schadstoffemissionen. Dasgupta, Laplante, Wang und Wheeler (2002) behaupten in diesem Zusammenhang, dass zwar die ersetzten Schadstoffe dem Verlauf der EKC Kurve folgen, die neuen Schadstoffe jedoch nicht.

Die parametrische Struktur des EKC Modells ist eingeschränkt, flexiblere parametrische Strukturen sind notwendig, um die Robustheit der EKC zu testen. Es gibt allgemeinere nicht-parametrische (Millimet, List und Stengos (2003)) und semi-parametrische (Bertinelli und Strobl (2005)) Ansätze für die EKC, sowie höher dimensionale Interpolationen (Schmalensee, Stoker und Judson (1998)), welche in dieser Arbeit nicht weiter verfolgt werden.

Für die Schätzung werden üblicherweise Paneldatenmodelle herangezogen, welche Homogenität der Koeffizienten über die Querschnittseinheiten implizieren. Vor allem bei den Studien der EKC Hypothese auf Makro-Paneldatenniveau treten große Probleme auf, da die untersuchten Länder starke Heterogenitäten aufweisen (Dijgraaf und Vollebergh (1998)). Lekakis (2000) begründet in seiner Arbeit, warum die EKC Hypothese für ein Land alleine untersucht werden soll. Mazzanti, Montini und Zoboli (2008) führen die Forschung der EKC Hypothese in eine neue Richtung. Sie untersuchen die EKC auf Mikro-Paneldatenniveau für Italien. Ein weiterer Anlass die Forschung in diese Richtung zu entwickeln, liefert die Aussage von Dinda (2004) über die Entwicklung einer Wirtschaft im Zusammenhang mit der EKC.

Erst in den letzten Jahren wurde den statistischen Eigenschaften der Daten Aufmerksamkeit geschenkt. Von fundamentaler Bedeutung für die Analyse der EKC Hypothese ist, dass die zugrundeliegenden Zeitreihen der einzelnen Querschnittseinheiten stationär sind. Den einzelnen statistischen Kritikpunkten wird in dieser Arbeit große Aufmerksamkeit geschenkt.

Kapitel 3

NAMEA Österreich

Eine NAMEA („National Accounts Matrix including Environmental Accounts“) Tabelle kann verschiedene umweltbezogene Daten mit Wirtschaftskennzahlen verbinden: Sie kann sich auf die Luftschadstoffemissionen, das Wasser oder die Abfallwirtschaft beziehen.

Für Österreich wird jährlich eine integrierte NAMEA Tabelle auf der Homepage der Statistik Austria publiziert. Diese verbindet Umweltdaten und Wirtschaftskennzahlen aus Österreich miteinander. Die Verbindungen werden aufgliedert in 19 Wirtschaftsbereiche dargestellt. Die NAMEA Österreich beinhaltet die ökonomischen Konten Bruttowertschöpfung, Produktionswert und Erwerbstätige in Vollzeitäquivalenten, die Emissionen von neun Luftschadstoffen, den Energieverbrauch, den Materialeinsatz, die Umweltschutzausgaben, die Ökosteuern und Gefährliche und Nichtgefährliche Abfälle. Die Tabelle wird im Zuge eines Projekts der EUROSTAT zur Erstellung jährlicher integrierter NAMEA Tabellen ausgeführt. Österreich nimmt seit 1997 an diesem Projekt teil. Im Moment ist die NAMEA Österreich für die Jahre 1995 bis 2007 verfügbar. Die Erhebung wird von der Statistik Austria durchgeführt. Die umweltbezogenen Daten werden vom Umweltbundesamt zur Verfügung gestellt.

Als Grundlage für die Gliederung dient die ÖNACE Klassifikation der Wirtschaftsbereiche. Die ÖNACE Klassifikation gewährleistet eine einheitliche Darstellung und sichert die Kompatibilität mit der Volkswirtschaftlichen Gesamtrechnung (VGR), was für viele Analysen vorteilhaft ist.

Ein Unterschied zur VGR besteht darin, dass die Privaten Haushalte als Verursacher und nicht wie in der ÖNACE Klassifikation als Produzenten miteinbezogen

werden. Daher kann es zu Abweichungen mit der VGR kommen, da der ÖNACE Steller Private Haushalte mit Hauspersonal nicht in der Gliederung vorkommt und deren Beitrag zur Bruttowertschöpfung und zum Produktionswert nicht berücksichtigt wird. Da die Privaten Haushalte in der NAMEA Tabelle als Konsumenten auftreten können sie für die EKC Analyse nicht miteinbezogen werden, es bleiben 18 Bereiche für die Analyse übrig. Die detaillierten Datenbeschreibungen werden ohne Bezug auf den Sektor Private Haushalte durchgeführt.

Die wirtschaftsbezogenen Daten müssen für die Verwendung in der NAMEA Tabelle angepasst werden, da die ÖNACE Klassifikation feiner als die der NAMEA ist. Die Bruttowertschöpfung und der Produktionswert werden in der NAMEA als verkettete Volumina zu Vorjahrespreisen dargestellt, wodurch Preisinflationen eliminiert werden können. Die entsprechenden Steller der ÖNACE Klassifikation werden jährlich aggregiert und im Anschluss die verketteten Volumina ermittelt. Die Erwerbstätigen werden in Vollzeitäquivalenten dargestellt. Auch sie müssen für die NAMEA entsprechend den Wirtschaftsbereichen aggregiert werden.

Die Luftschadstoffemissionen werden in der NAMEA Tabelle in Tonnen gemessen. Die Datenerhebung erfolgt auf Basis von SNAP, einem Programm, das die Emissionen in Bezug auf Wirtschaftstätigkeiten misst. Die Aufgliederung der Emissionen in SNAP ist verschieden von der ÖNACE Klassifikation. Ein wesentlicher Arbeitsschritt ist es diese Wirtschaftstätigkeiten den einzelnen Sektoren der NAMEA Österreich zuzuordnen. Problematisch in diesem Zusammenhang ist die Zuordnung des Verkehrs auf die einzelnen Sektoren.

Durch Kombination der ÖNACE Klassifikation und der SNAP Gliederung entstand die Einteilung der NAMEA Österreich in die 19 Wirtschaftsbereiche.

Im Projektbericht der Statistik Austria wird angemerkt: *„Es handelt sich bei den berichteten Luftschadstoffemissionen um jene, die von österreichischen institutionellen Einheiten im Inland sowie im Ausland verursacht werden.“* (Baud (2009), Seite 23) Deswegen kann es zu Abweichungen mit anderen Publikationen kommen, welche die Emissionen im Inland gesamt messen, wie beispielsweise das Umweltbundesamt.

Die Sektoren der NAMEA Österreich können nach der Drei-Sektoren-Hypothese aufgeteilt werden: Der Primärsektor umfasst die Landwirtschaft und setzt sich aus einem Sektor zusammen. Der Sekundärsektor Industrie inklusive Bauwirtschaft oder Industrieller Sektor besteht aus 13 Sektoren. Der Tertiärsektor umfasst die

Dienstleistung und besteht aus vier Sektoren. Eine Auflistung aller Sektoren befindet sich in Tabelle 3.1.

Tabelle 3.1: Gliederung der NAMEA Österreich

	Wirtschaftsbereich	ÖNACE Steller
Landwirtschaft	Sektor 19: Landwirtschaft	01, 02, 05
Industrie inkl. Bauwirtschaft	Sektor 1: Eisen- und Stahlerzeugung	27
	Sektor 2: Chemie und Petrochemie	23, 24
	Sektor 3: Steine und Erden, Glas	26
	Sektor 4: Fahrzeugbau	34, 35
	Sektor 5: Maschinenbau	28-32
	Sektor 6: Bergbau	10-14
	Sektor 7: Nahrungs- und Genussmittel, Tabak	15, 16
	Sektor 8: Papier und Druck	21, 22
	Sektor 9: Holzverarbeitung	20
	Sektor 10: Bau	45
Dienstleistung	Sektor 11: Textil und Leder	17-19
	Sektor 12: Sonstiger Produzierender Bereich	25, 33, 36, 37
	Sektor 17: Energieverbrauch	40
	Sektor 13: Landverkehr	60
	Sektor 14: Binnenschifffahrt	61
	Sektor 15: Flugverkehr	62
	Sektor 16: Öffentliche und Private Dienstleistungen	41, 50-52, 55, 63-67, 70-75, 80, 85, 90-93

Die Abbildung 3.1 zeigt die jährlichen Mittel der Zeitreihen Produktionswert, Bruttowertschöpfung, Kohlendioxid, Kohlenmonoxid, Methan, Stickoxid und Schwefeldioxid dividiert durch das jährliche Mittel der Erwerbstätigen in Form eines Indexes mit 1995 = 100. Das entspricht den aggregierten Zeitreihen. Die Abbildung ist nicht in der Lage die individuelle Heterogenität des Datensatzes wiederzugeben, zeigt aber die Entwicklung der Emissionen und der Wirtschaft gesamt. Die Wirtschaft ist im betrachteten Zeitraum gesamt gewachsen. Sowohl der Produktionswert als auch die Bruttowertschöpfung haben einen Zuwachs erzielt. Der Ausstoß von Kohlenmonoxid, Methan und Schwefeldioxid wurde reduziert. Kohlendioxid und Stickoxid verzeichneten einen stärkeren Anstieg als die Bruttowertschöpfung.

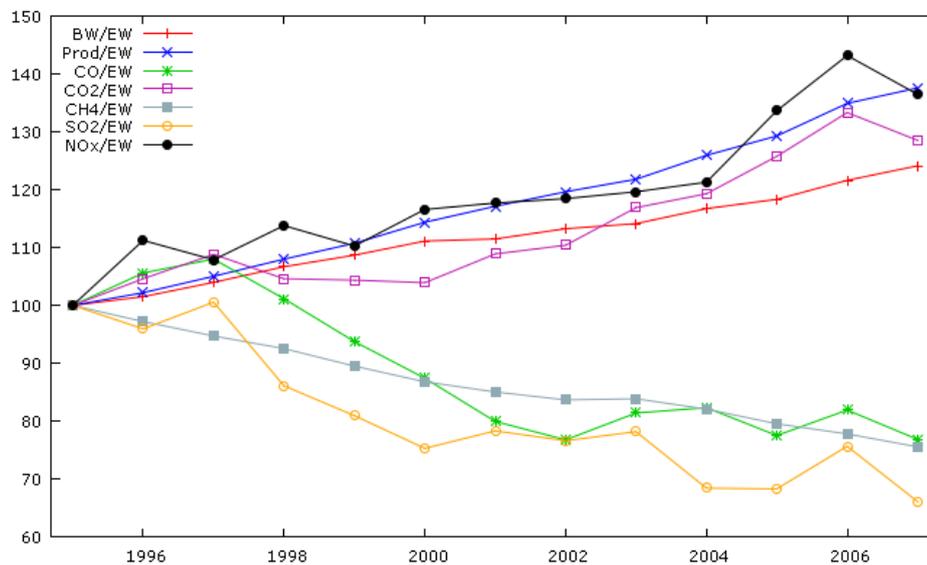


Abbildung 3.1: Zeitreihen der Luftschadstoffemissionen und ökonomischen Variablen dividiert durch die Erwerbstätigen 1995-2007 mit Index 1995 = 100

Eine erste Analyse der Daten:

Die durchgeführte Analyse stützt sich auf den Projektbericht der Statistik Austria [12]. Der Sektor Private Haushalte wird aus der Beschreibung der Daten ausgegliedert.

Der **Produktionswert** (Prod) erhöhte sich von 1995-2007 insgesamt um 50% auf 488,2 Mrd. € absolut. Der Sektor Textil und Leder verzeichnete als einziges einen Rückgang des Produktionswerts, in allen anderen Sektoren konnten Zuwächse erzielt werden. Der Fahrzeugbau, die Energieversorgung und der Flugverkehr erwirtschafteten die stärksten Zuwächse.

Die **Bruttowertschöpfung** (BW) stieg um insgesamt 35,5% auf 236 Mrd. € absolut. Das größte Wachstum erzielte der Sektor Fahrzeugbau, gefolgt vom Sektor Chemie und Petrochemie. Die Bruttowertschöpfung von Textil und Leder sank am stärksten. Interessante Entwicklungen verzeichneten der Flugverkehr und die Binnenschifffahrt. Ihre Zeitreihen schwankten sehr stark.

Zu den größten Sektoren der Bruttowertschöpfung und des Produktionswerts gehö-

ren der Sektor Öffentliche und Private Dienstleistungen, der Sektor Maschinenbau und der Sektor Bau.

Die **Erwerbstätigen in Vollzeitäquivalenten** (EW) verzeichneten ein Wachstum von 9,1% auf 3,62 Mio. absolut. Der Fahrzeugbau, der Flugverkehr und die Öffentlichen und Privaten Dienstleistungen steigerten ihren Arbeitsbedarf am meisten. Weniger Arbeitskräfte wurden bei Textil und Leder und in der Binnenschifffahrt benötigt.

Zu den wichtigsten Arbeitgebern zählen die Sektoren Öffentliche und Private Dienstleistungen, Maschinenbau, Bau und Landwirtschaft.

Die **Schwefeldioxidemissionen** (SO₂) konnten von 1995-2007 um 28% eingeschränkt werden. Absolut erreichten sie 2007 einen Wert von 20.720,38t.

Verursacht wird SO₂ hauptsächlich durch das Verbrennen von schwefelhaltigen Brenn- und Treibstoffen. Da Schwefeldioxid als Hauptverursacher des sauren Regens gilt, reichen die Bemühungen zur Einschränkung der SO₂ Emissionen bis Anfang der 80er Jahre zurück. Es wurden Filter in die Verbrennungsanlagen der Kraftwerke eingebaut, schwefelhaltige Brennstoffe durch schwefelärmere ersetzt, sowie der Schwefelanteil in Treibstoffen reduziert. 2000 betrug die Schwefelemissionen ein Zehntel des Werts von 1980. Ganz Österreich wird heute flächendeckend mit schwefelfreiem Treibstoff beliefert.

Die Sektoren Eisen- und Stahlerzeugung und Chemie und Petrochemie zählen zu den wichtigsten Verursachern von SO₂ Emissionen, gemeinsam produzierten sie 2007 41,8% des gesamten SO₂s. Außerdem stieg der Emissionsausstoß der Eisen- und Stahlerzeugung absolut am Größten.

Die **Stickoxidemissionen** (NO_x) stiegen von 1995-2007 um 48,8%. 2007 wurden absolut 158.717,66t ausgestoßen.

Der Schadstoffausstoß von NO_x stieg für den betrachteten Zeitraum unter allen betrachteten Luftschadstoffen am stärksten. NO_x wird hauptsächlich bei der Verbrennung von Brenn- und Treibstoffen verursacht.

Für die Zuwächse ist vor allem der Sektor Landverkehr verantwortlich. Er verzeichnete einen prozentuellen Anstieg von 132,9%. Die größten Produzenten sind die Landwirtschaft und die Bauwirtschaft. Papier und Druck und Steine, Erden und Glas hingegen konnten ihre Produktion an NO_x deutlich einsparen.

Von 2006 auf 2007 kam es zu einer Verminderung des Ausstoßes um 3,2%. Dieser

erklärt sich durch den verminderten Dieselaussatz, den technologischen Fortschritt der Fahrzeuge und die milde Heizperiode.

Die **Methanemissionen** (CH₄) sanken von 1995-2007 um 17,6% auf 319.383,96t absolut.

Die Emissionen entstehen zu einem großen Teil beim Verdauungsprozess von Tieren in der Landwirtschaft, sowie bei der Abfalldeponierung.

Die wichtigsten Emittenten sind die Sektoren Landwirtschaft und Öffentliche und Private Dienstleistungen, da sie die Abfallwirtschaft beinhalten. Sie waren aber auch für den größten Teil der Verminderungen verantwortlich. Zu vermehrtem Ausstoß kam es in der Holzverarbeitung.

Die **Kohlenmonoxidemissionen** (CO) konnten von 1995-2007 um 16,2% eingeschränkt werden, 2007 wurden absolut 286.944t produziert.

Der Ausstoß wird hauptsächlich bei der Verbrennung von Brenn- und Treibstoffen in Heizanlagen und Brennöfen verursacht. Der Rückgang konnte durch die Verringerung des Emissionsausstoßes in der Eisen- und Stahlerzeugung erzielt werden. Landwirtschaft und Steine, Erden und Glas hingegen verzeichneten einen Zuwachs an CO Emissionen.

Die größten Einsparungen für Kohlenmonoxid erzielten die Privaten Haushalte durch die Erneuerung veralteter Heizungsanlagen. Diese Verbesserung fließt in die Analyse dieser Arbeit nicht ein.

Die **Kohlendioxidemissionen** (CO₂) stiegen von 1995-2007 gesamt um 40,2% auf 69.991.267,96t absolut.

In der neuesten Version der NAMEA werden die CO₂ Emissionen getrennt nach Emissionen aus biogenen Quellen und Emissionen exkl. biogener Quellen angegeben. Diese Trennung beruht auf der Tatsache, dass CO₂ aus biogenen Quellen in klimapolitischer Sicht als neutral angesehen wird. In der weiteren Analyse wird CO₂ gemeinsam betrachtet.

Die größten Emittenten sind die Sektoren Landverkehr, Eisen- und Stahlerzeugung und Energieversorgung.

Die betrachteten Schadstoffe lassen sich in zwei Gruppen einteilen. Die Gruppe der Treibhausgase umfasst CH₄ und CO₂, die der lokalen Luftschadstoffemissionen CO, NO_x und SO₂.

Kapitel 4

Modelle für Paneldaten

Zur Analyse von Paneldaten haben sich zwei verschiedene Modellklassen, das „Fixed und das Random Effects“ Modell, durchgesetzt. Für diese werden die Modellspezifikationen hergeleitet und die grundlegenden Annahmen erläutert. Die Ausführungen folgen Wooldridge (2002) [88].

Zusätzlich zu den präsentierten Paneldatenmodellen existieren auch Dynamische Panelmodelle auf die in dieser Arbeit nicht eingegangen wird.

Grundsätzlich hat ein Modell für Paneldaten folgende Form:

$$y_{it} = \gamma_t + \beta x_{it} + v_{it} \quad (4.1)$$

$$v_{it} = c_i + u_{it} \quad (4.2)$$

Die Gleichung (4.1) beschreibt die Modellgleichung und (4.2) die Struktur des Fehlerterms.

y_{it} sind die erklärten Variablen und x_{it} die beobachtbaren erklärenden Variablen, welche sich über die Perioden t oder die Querschnittseinheiten i oder über beide Einheiten verändern können. Die x_{it} werden als strikt exogen angenommen.

Der Fehler v_{it} setzt sich aus zwei Komponenten zusammen: c_i , dem individuellen Effekt oder auch die individuelle Heterogenität, und u_{it} , dem idiosynkratischem Fehler. γ_t bezeichnet die individuellen Zeitperiodenkonstanten. Diese können im Modell vorhanden sein, müssen es aber nicht.

Die Modelle unterscheiden sich in der Betrachtung des Fehlers c_i . Dieser kann als „Fixed Effect“ oder als „Random Effect“ betrachtet werden, somit im Modell

geschätzt oder als Zufallsvariable angenommen werden. Besonders in verfahrenstechnischen Papers ist diese Betrachtungsweise üblich, Wooldridge (2002) kritisiert in seinem Buch diese Unterscheidung, da sie vor allem in der Mikroökonomie nicht zutrifft. Für Wooldridge (2002) liegt der Kernpunkt in der Betrachtung von c_i in der Frage ob diese mit den erklärenden Variablen korreliert sind oder nicht. Für das „Fixed Effects“ Modell besteht eine Korrelation zwischen x_{it} und c_i , das „Random Effects“ Modell betrachtet sie als unabhängig.

4.1 Pooling

Pooling ist die einfachste Form Paneldaten zu untersuchen, dabei wird auf die Struktur des Fehlerterms nicht eingegangen und die Heterogenität des Modells nicht beachtet. v_{it} in Gleichung (4.2) wird gemeinsam als „ein“ Fehler betrachtet, Wooldridge (2002) spricht in diesem Zusammenhang vom „gemischten Fehler“.

Die Modellstruktur reduziert sich damit auf:

$$y_{it} = \beta x_{it} + v_{it} \quad (4.3)$$

Es wird eine gemeinsame Schätzung aller Daten, eine gepoolte OLS Regression, durchgeführt. Diese kann konsistent geschätzt werden, wenn $\mathbf{E}[x'_{it} v_{it}] = 0$ erfüllt ist. Das bedeutet, dass es keine Korrelation zwischen x_{it} und c_i , sowie zwischen x_{it} und u_{it} geben darf.

4.2 Das „Random Effects“ Modell

$$y_{it} = \beta x_{it} + v_{it} \quad (4.4)$$

$$v_{it} = c_i + u_{it} \quad (4.5)$$

Wie zuvor wird beim „Random Effects“ (RE) Modell c_i als ein Bestandteil des Fehlerterms betrachtet. Zusätzlich wird angenommen, dass die c_i orthogonal zu den x_{it} sind. Die expliziten Annahmen des RE Modells lauten:

$$\mathbf{E}[u_{it} | x_i, c_i] = 0 \quad t = 1, \dots, T \quad (4.6)$$

$$\mathbf{E}[c_i | x_i] = \mathbf{E}[c_i] = 0, \quad (4.7)$$

wobei x_i den T -dimensionalen Vektor der i -ten Querschnittseinheit bezeichnet.

(4.6) stellt die Exogenitätseigenschaft sicher, (4.7) beschreibt die Orthogonalitätseigenschaft von c_i und x_{it} .

Für die Varianzmatrix der Fehler v_{it} , bezeichnet mit $\Omega = \mathbf{E}[v_i v_i']$, muss gelten:

$$\text{rank}(X_i' \Omega^{-1} X_i) = K, \quad (4.8)$$

wobei X_i die $T \times K$ -Matrix der Daten bezeichnet. Die $T \times T$ -Matrix Ω wird als positiv definit angenommen.

Diese Annahmen garantieren eine konsistente FE Schätzung. Sie werden benötigt um die allgemeine Kleinst-Quadrate Methode (GLS) anwenden zu können.

Um auf die serielle Korrelation des gemischten Fehlers einzugehen, stellt das „Random Effects“ Modell zusätzliche Annahmen an die Struktur von Ω .

Die idiosynkratischen Fehler u_{it} haben eine konstante Varianz in Bezug auf t : $\mathbf{E}[u_{it}^2] = \sigma_u^2$. Außerdem sind sie seriell unkorreliert: $\mathbf{E}[u_{it}' u_{is}] = 0$ für alle $s \neq t$. Für die individuellen Effekte c_i gilt: $\mathbf{E}[c_i^2] = \sigma_c^2$.

Das liefert explizit folgende Annahmen:

$$\mathbf{E}[u_{it}' u_{it} | x_i, c_i] = \sigma_u^2 \quad (4.9)$$

$$\mathbf{E}[c_i^2 | x_i] = \sigma_c^2 \quad (4.10)$$

Damit ist Ω nur noch von σ_u^2 und σ_c^2 abhängig und hat die spezielle Form:

$$\Omega = \begin{pmatrix} \sigma_c^2 + \sigma_u^2 & \sigma_c^2 & \dots & \sigma_c^2 \\ \sigma_c^2 & \sigma_c^2 + \sigma_u^2 & \dots & \vdots \\ \vdots & \dots & \ddots & \sigma_c^2 \\ \sigma_c^2 & \dots & \dots & \sigma_c^2 + \sigma_u^2 \end{pmatrix}$$

Außerdem garantiert diese Annahme die Effizienz des RE Schätzers in der Klasse der Schätzer, welche $\mathbf{E}[v_i | x_i] = 0$ erfüllen. Dazu gehört auch der gepoolte OLS Schätzer.

Hat man konsistente Schätzer für die beiden gefunden, $\hat{\sigma}_u^2$ und $\hat{\sigma}_c^2$, kann der GLS Schätzer für β_{RE} bestimmt werden:

$$\hat{\beta}_{RE} = \left(\sum_{i=1}^N X_i' \hat{\Omega}^{-1} X_i \right)^{-1} \left(\sum_{i=1}^N X_i' \hat{\Omega}^{-1} y_i \right) \quad (4.11)$$

Zur Schätzung von σ_u^2 und σ_c^2 :

Am einfachsten ist es zuerst $\hat{\sigma}_v^2 = \hat{\sigma}_c^2 + \hat{\sigma}_u^2$ zu schätzen. Dazu wird der OLS Schätzer von β benötigt. Seien \tilde{v}_{it}^2 die OLS Residuen, dann ist $\hat{\sigma}_v^2 = \frac{1}{(NT-K)} \sum_{i=1}^N \sum_{t=1}^T \tilde{v}_{it}^2$ ein konsistenter Schätzer für σ_v^2 .

Ein konsistenter Schätzer für σ_c^2 kann ebenfalls durch Verwendung der OLS Residuen gefunden werden: $\hat{\sigma}_c^2 = \frac{1}{\frac{NT(T-1)}{2} - K} \sum_{i=1}^N \sum_{t=1}^{T-1} \sum_{s=t+1}^T \tilde{v}_{it} \tilde{v}_{is}$.

Nun kann σ_u^2 durch $\hat{\sigma}_u^2 = \hat{\sigma}_v^2 - \hat{\sigma}_c^2$ ermittelt werden. Es ist auch möglich σ_u^2 durch Verwendung der „Fixed Effects“ Methode zu bestimmen.

Ist σ_c^2 gleich Null, so reduziert sich der FE Schätzer zu dem gepoolten Schätzer. Diese Tatsache wird für die Unterscheidung des RE und des gepoolten Modells verwendet. Der Breusch-Pagan Test hat die Nullhypothese, dass die Varianz von σ_c^2 gleich Null ist. Wird die Nullhypothese nicht verworfen, kann geschlossen werden, dass das gepoolte Modell den Daten am Besten entspricht.

4.3 Das „Fixed Effects“ Modell

Beim „Fixed Effects“ (FE) Modell wird c_i als korreliert mit den x_{it} angenommen und der Zusammenhang explizit geschätzt.

Das Modell schreibt sich in diesem Fall als:

$$y_{it} = \beta x_{it} + c_i + u_{it} \quad (4.12)$$

Auch für den FE Schätzer wird die strikte Exogenität der x_{it} gefordert:

$$\mathbf{E}[u_{it}|x_i, c_i] = 0 \quad t = 1, \dots, T \quad (4.13)$$

Der zweite Teil der Annahme des RE Modells (4.7) wird in diesem Fall nicht gefordert, $\mathbf{E}[c_i|x_i]$ kann irgendeine Funktion von x_i sein. Das Weglassen des zweiten Teils führt dazu, dass die Effekte von periodenkonstanten Variablen, welche mit x_{it} korreliert sein können, gemeinsam mit den c_i geschätzt werden. Daraus folgt, dass der FE Schätzer robuster als der RE Schätzer ist. Ohne zusätzliche Annahmen können beim FE Modell keine zeitinvarianten Konstanten geschätzt werden, da sie von den unbeobachteten c_i nicht unterscheidbar sind.

Die Idee des Fixed Effects Schätzers ist es die Gleichungen so zu transformieren, dass die c_i eliminiert werden. Das ist möglich sobald mehr als eine Gleichung vor-

handen ist. Die Transformation wird „Within Transformation“ genannt, da sie auf die Periodenvariation innerhalb jeder Querschnittseinheit eingeht. Zuerst werden die Mittel für alle Querschnittseinheiten ermittelt:

$$\bar{y}_i = \beta \bar{x}_i + c_i + \bar{u}_i, \quad (4.14)$$

wobei $\bar{y}_i = \frac{1}{T} \sum_{t=1}^T y_{it}$, $\bar{x}_i = \frac{1}{T} \sum_{t=1}^T x_{it}$ und $\bar{u}_i = \frac{1}{T} \sum_{t=1}^T u_{it}$. Dann wird die Gleichung (4.14) von (4.12) subtrahiert:

$$y_{it} - \bar{y}_i = \beta (x_{it} - \bar{x}_i) + u_{it} - \bar{u}_i \quad t = 1, \dots, T \quad (4.15)$$

Zur Vereinfachung sei: $\bar{\bar{y}}_{it} = y_{it} - \bar{y}_i$, $\bar{\bar{x}}_{it} = x_{it} - \bar{x}_i$ und $\bar{\bar{u}}_{it} = u_{it} - \bar{u}_i$

Damit wurde der individuelle Effekt c_i aus den Gleichungen eliminiert und der Fixed Effects Schätzer kann durch Anwenden einer gepoolten OLS Regression konsistent ermittelt werden:

$$\hat{\beta}_{FE} = \left(\sum_{i=1}^N \bar{\bar{X}}_i' \bar{\bar{X}}_i \right)^{-1} \left(\sum_{i=1}^N \bar{\bar{X}}_i' \bar{\bar{y}}_i \right) \quad (4.16)$$

Um zu garantieren, dass der FE Schätzer sich asymptotisch normal verhält, wird die Rangbedingung:

$$\text{rank}(\mathbf{E}[\bar{\bar{X}}_i' \bar{\bar{X}}_i]) = K \quad (4.17)$$

gefordert. Damit ist der FE Schätzer bedingt unverzerrt in Bezug auf X_i .

Der „Fixed Effects“ Schätzer ist effizient, wenn die zusätzliche Voraussetzung:

$$\mathbf{E}[u_i u_i' | x_i, c_i] = \sigma_u^2 \quad (4.18)$$

erfüllt ist. Diese Annahme ist ähnlich der Annahme (4.10) des RE Modells. Aus ihr folgt, dass die idiosynkratischen Fehler u_{it} eine konstante Varianz über die Perioden haben und seriell unkorreliert sind.

Alternativ zur „Within Schätzung“ kann eine „Between Schätzung“ durchgeführt werden, diese beachtet nur die Variation zwischen den Querschnitteinheiten. Sie wird durch eine OLS Schätzung ausgehend von (4.14) durchgeführt. Der Schätzer muss nicht konsistent sein, da $E[\bar{x}_i'c_i] = 0$ nicht automatisch erfüllt sein muss.

Um die individuellen Querschnittskonstanten c_i mitzubestimmen, werden N Dummy Variablen in die Schätzung miteinbezogen, einer für jede Querschnitteinheit. Für die Dummy Variable dn_i der i -ten Einheit gilt: $dn_i = 1$ wenn $n = i$ und $dn_i = 0$ sonst. Es wird eine OLS Regression von \bar{y}_{it} auf $d1_i, d2_i, \dots, dN_i, \bar{x}_{it}$ durchgeführt und $d1_i$ ist dann c_1 , $d2_i$ gleich c_2 und so weiter. Aus dieser Beziehung folgt, dass der FE Schätzer auch „Least Squares Dummy Variable (LSDV)“ Schätzer genannt wird.

Das Problem bei der Schätzung ist, dass für jede zusätzliche Querschnitteinheit ein neues c_i hinzukommt und sich damit die Schätzung ändert. Sie ist im Gegensatz zum ursprünglichen FE Schätzer für $N \rightarrow \infty$ nicht gültig.

Sind alle c_i s gleich (d.h. gilt $c_i = c$ für alle i), so reduziert sich der FE Schätzer zu einem gepoolten Schätzer, welcher in der X_i Matrix zusätzlich einen Vektor von Einsen enthält. Für die Unterscheidung des „Fixed Effects“ und des gepoolten Modells kann deshalb ein normaler F-Test mit der Nullhypothese, dass alle Querschnitteinheiten die selbe Konstante haben, verwendet werden.

4.4 Vergleich des „Random und Fixed Effects“ Modells

Das „Fixed Effects“ Modell beschreibt den Zusammenhang zwischen erklärenden und erklärten Variablen innerhalb einer Querschnitteinheit für jede Querschnitteinheit einzeln. Jede kann dabei ihre eigenen Charakteristika haben. Das bedeutet für jede Einheit kann eine individuelle Konstante und ein individueller Fehlerterm geschätzt werden, welche nicht mit anderen Einheiten korreliert sein sollten. In diesem Fall sind die geschätzten Parameter abhängig von den Daten und somit zeit- und landbezogen.

Ein Problem der FE Schätzung ist, dass zeitinvariante Konstanten nicht geschätzt werden können, da sie von den individuellen Konstanten absorbiert werden und von diesen nicht unterscheidbar sind.

Beim „Random Effects“ Modell wird angenommen, dass die Variation über die

Querschnittseinheiten zufällig ist und mit den unabhängigen Variablen unkorreliert ist. Das RE Modell erlaubt Rückschlüsse eines Datensatzes auf andere Datensätze zu generalisieren.

Die RE Schätzung kann zeitinvariante Konstanten schätzen. Sie können zur Erklärung der Variablen beitragen.

Bei der Modellschätzung ist zu beachten, dass wenn x_{it} und u_{it} in irgendeiner Weise korreliert sind, keines der beiden Modelle konsistent geschätzt werden kann. Sind sie nicht korreliert, ist der FE Schätzer immer konsistent, egal ob x_{it} mit c_i korreliert ist oder nicht.

Sind die c_i orthogonal auf x_{it} ist der RE Schätzer konsistent und in Bezug auf den FE Schätzer effizient.

Ist hingegen die FE Schätzung die richtige, das heißt sind die c_i mit x_{it} korreliert, ist der RE Schätzer inkonsistent.

Wenn die Variablen x_{it} kaum über die Zeit variieren, führt der FE Schätzer zu ungenauen Ergebnissen. In diesem Fall sollte eine RE Schätzung durchgeführt werden.

Um zwischen FE und RE Modell entscheiden zu können wurde von Hausman (1978) ein Test entwickelt.

Die **Hausman Teststatistik** beruht auf der Differenz zwischen dem FE und RE Schätzer, die miteinander verglichen werden. Ein signifikanter Unterschied der Schätzer deutet an, dass das RE Modell nicht konsistent geschätzt werden kann, in diesem Fall sind x_{it} und c_i miteinander korreliert und das FE Modell kann konsistent geschätzt werden.

Die Hausman Teststatistik wird wie folgend dargestellt:

$$T = (\hat{\beta}_{FE} - \hat{\beta}_{RE})' (V(\hat{\beta}_{FE}) - V(\hat{\beta}_{RE}))^{-1} (\hat{\beta}_{FE} - \hat{\beta}_{RE}), \quad (4.19)$$

wobei $V()$ die Varianz-Kovarianzmatrix des entsprechenden Schätzers bezeichnet. Unter der Nullhypothese trifft das RE Modell zu, diese wird verworfen wenn T größer ist als das entsprechende Quantil der χ^2 -Verteilung mit K Freiheitsgraden.

Um diese Modelle schätzen zu können, müssen für die verwendeten Daten gewisse statistische Eigenschaften erfüllt sein. Sind die betrachteten Daten nicht stationär, verliert der Zusammenhang zwischen dem Umweltindikator und der wirtschaftlichen Entwicklung jegliche Grundlage und die Panelmodelle ihre Gültigkeit.

4.5 Die ökonometrische Kritik der EKC Kurve

In der Geschichte der EKC Kurve wurden folgende statistische Kritikpunkte von verschiedenen Autoren geäußert.

1. Der bedeutendste Kritikpunkt bei der Schätzung der EKC Kurve ist die Stationarität der Daten, welche in vielen Analysen nicht untersucht wird.

Wagner und Müller-Fürstenberger (2004) und Wagner (2008) kritisieren vor allem diese Tatsache. Ihre Kritik lässt sich in drei Punkte unterteilen.

Der erste Punkt kritisiert die Verwendung nicht stationärer Zeitreihen und im Weiteren die Transformationen dieser Zeitreihen für die Schätzung der EKC. Dieses Problem ist fundamental. Die Annahme, dass die Variablen nicht stationär sind, trifft in sehr vielen Fällen zu. Außerdem werden für die Regressionen zusätzlich zu den Zeitreihen der erklärenden Variablen auch deren Quadrat und dritte Potenz verwendet. Diese müssen aber nicht dasselbe asymptotische Verhalten aufweisen wie die ursprüngliche Zeitreihe. Wagner und Müller-Fürstenberger (2004) führen ein einfaches Beispiel an, um den Sachverhalt zu schildern: Ein einfacher Random Walk $x_t = \sum_{i=1}^t \varepsilon_i$, mit ε_i weißem Rauschen, ist Unit Root-stationär, das bedeutet seine erste Differenz ist stationär. Das Quadrat des Prozesses $x_t^2 = (\sum_{i=1}^t \varepsilon_i)^2$ erfüllt diese Eigenschaft nicht. Die erste Differenz des Quadrats ist immer noch nicht stationär.

Mit Hilfe von Einheitswurzeltests können die Daten auf Stationarität untersucht werden. Für die Analyse der Verwendung von transformierten nicht stationären Zeitreihen gibt es in der Literatur erst wenige Ansätze. Chang, Park Phillips (2001) und Park und Phillips (1999,2001) haben sich mit diesem Problem im Kontext einfacher Zeitreihen beschäftigt.

In der Arbeit wird dieses Problem umgangen indem auch das Quadrat und die dritte Potenz der unabhängigen Variablen mit den Einheitswurzeltests für Paneldaten auf Stationarität untersucht werden. Diese Vorgehensweise folgt Galeotti, Manera und Lanza (2008). Trotzdem bleibt anzumerken, dass das nur ein erster Schritt ist, um die Transformationen auf Stationarität zu untersuchen.

Die beiden weiteren Kritikpunkte beschäftigen sich mit der Durchführung der statistischen Tests zur Untersuchung des Paneldatensatzes auf Stationari-

tät. Wenn Einheitswurzeltests durchgeführt werden, so werden die einzelnen Zeitreihen des Panels als querschnittsunabhängig angenommen, was aber bei Betrachtung der Daten als unwahrscheinlich gilt.

Die Zeitdimension der Paneldatensätze ist meist sehr kurz und daher liefern die verwendeten statistischen Methoden für die einzelnen Zeitreihen keine signifikanten Ergebnisse. Das wirkt sich direkt auf die Teststatistiken der Einheitswurzeltests aus.

Für die beiden letzten Kritikpunkte wurden in den letzten Jahren neue Methoden entwickelt. Es gibt bereits eine Vielzahl an Ansätzen für Unit Root Tests, welche Querschnittsabhängigkeiten behandeln können. Auf das Problem der Stationarität der Daten wird in Kapitel 4 genauer eingegangen. Es enthält einen Überblick über die Entwicklungen der Einheitswurzeltests für Paneldaten der letzten Jahre.

2. Der zweite Kritikpunkt behandelt die Kointegration der Daten.

Galeotti, Manera und Lanza (2009) argumentieren, dass wenn der Umweltindikator und die erklärende Variable eine Einheitswurzel besitzen, müssen Kointegrationstests für diese Variablen durchgeführt werden. Sind beide integriert der Ordnung 1 und sind die Residuen der EKC Regression stationär, so sind die beiden kointegriert und die EKC Schätzung ist stationär. Das beruht auf den Erkenntnissen von Engle und Granger (1987).

Kointegrationstests für Paneldatensätze wurden unter anderen von Pedroni (2004) und Kao (1999) entwickelt.

3. Ein weiterer Kritikpunkt ist die Heteroskedastizität der Daten.

Stern, Common und Barbier (1996) haben auf das Problem der Heteroskedastizität in Zusammenhang mit Regressionen von gruppierten Daten aufmerksam gemacht. Schmalensee, Stoker und Judson (1998) konnten zeigen, dass die Regressionsresiduen einer Schätzung der EKC Kurve heteroskedastisch sind. Für verschiedene Länder konnten kleinere Werte des BIPs und der Population mit größeren Residuen identifiziert werden. Stern (2002) führt eine GLS Schätzung unter Berücksichtigung der Heteroskedastizität durch. Die Anpassung an die Daten konnte dadurch deutlich verbessert werden.

4. Der letzte Kritikpunkt befasst sich mit der Verzerrung der Schätzer. Stern

und Common (2001) merken an, dass die Schätzer der EKC Modelle auf drei Ebenen verzerrt sein können: Erstens können Strukturbrüche auftreten und daher die geschätzten Koeffizienten zwischen verschiedenen Teilbereichen des Datensatzes verzerrt sein. Zweitens können die Schätzer durch serielle Korrelation der Variablen verzerrt sein. Drittens können die Schätzer durch die falsche Modellwahl zwischen „Random und Fixed Effects“ Modell verzerrt sein.

Im Folgenden werden Einheitswurzeltests für Paneldaten durchgeführt, um den fundamentalsten Kritikpunkt der EKC Literatur zu behandeln. Die Ergebnisse dieser Tests entscheiden, ob die Variablen stationär sind oder nicht und daher ob Ko-integrationstests durchgeführt werden müssen oder nicht. Sie bilden die Grundlage für die Sinnhaftigkeit der Schätzung einer EKC Kurve für die NAMEA Österreich.

Kapitel 5

Tests auf Einheitswurzeln

Tests auf Einheitswurzeln (EW) (Unit Root (UR)) testen einen stochastischen Prozess x_t auf Integration 1.Ordnung. x_t wird integriert 1.Ordnung oder Unit Root-stationär genannt, wenn seine erste Differenz $\Delta x_t = x_t - x_{t-1}$ stationär ist, x_t selbst jedoch nicht.

Das Testprinzip wurde ursprünglich von Dickey-Fuller (DF) (1979) entwickelt. Prinzipiell wird in $x_t = \rho x_{t-1} + u_t$ die Nullhypothese der Nichtstationarität gegen die Alternativhypothese eines autoregressiven Prozesses 1.Ordnung (AR(1)) getestet. Da das Testprinzip sehr vereinfacht ist, wurden zusätzliche Terme, verzögerte Differenzen von x_{it} in die Teststatistik hinzugefügt. Dieses Verfahren wird Augmented Dickey-Fuller Test (ADF) genannt.

5.1 Allgemeine Theorie

Die in der Literatur gebräuchlichen Einheitswurzeltests für Zeitreihen eignen sich für Panels mit einer mittleren Anzahl an Querschnittseinheiten (10 bis 50) und Perioden (10 bis 80), wie die NAMEA Daten, nicht. Die Teststatistiken liefern keine brauchbaren Ergebnisse, da sie nicht auf die Querschnittsstruktur von Paneldaten eingehen. Um Panels dieser Art auf Einheitswurzeln zu untersuchen, wurden Panel Unit Root Tests entwickelt. Diese sind im Gegensatz zu den Einheitswurzeltests für Zeitreihen, deren Grenzverteilungen Formen der Brown'schen Bewegung sind, unter der Nullhypothese durch Standard-Verteilungen, wie die Normalverteilung, gekennzeichnet.

Prinzipiell hat ein Einheitswurzeltest folgende Form: Sei x_{it} die Variable für die man feststellen möchte, ob sie eine Einheitswurzel besitzt. Getestet wird die Nullhypothese $H_0 : \rho_i = 1$ für alle $i = 1, \dots, N$ in

$$x_{it} = \alpha_{it} + \rho_i x_{it-1} + u_{it}, \quad (5.1)$$

wobei N die Anzahl der Querschnittseinheiten und T die der Perioden ist. Der Störterm u_{it} wird als ein stationärer Prozess dargestellt, welcher als querschnittsunabhängig angenommen wird. α_{it} ist eine deterministische Komponente, welche die verschiedenen Modellarten kennzeichnet. Sie kann Null, eine Konstante (Mittelwert) α_{i0} oder eine Konstante und einen linearen Trend $\alpha_{i0} + \alpha_{i1}t$ darstellen. Unter der Nullhypothese hat die getestete Variable eine Einheitswurzel und ist somit nicht stationär.

Gebräuchlich ist auch die Darstellung in Differenzen:

$$\Delta x_{it} = \phi_i x_{it-1} + u_{it}, \quad (5.2)$$

wobei gilt $\Delta x_{it} = x_{it} - x_{it-1}$ und $\phi_i = \rho_i - 1$.

Der DF Test kann durch die verzögerten Differenzen der Zeitreihe erweitert werden:

$$\Delta x_{it} = \phi_i x_{it-1} + \gamma_1 \Delta x_{it-1} + \dots + \gamma_{p_i} \Delta x_{it-p_i} + u_{it}. \quad (5.3)$$

In diesem Fall spricht man vom Augmented Dickey Fuller Test. Die Ordnung p_i der $AR(p_i)$ -Prozesse kann für die einzelnen Querschnittseinheiten homogen, $p_i = p$ für alle i , oder unterschiedlich sein.

Die Tests unterscheiden sich in der Formulierung der Gegenhypothese. Es gibt zwei Typen von Gegenhypotesen: die homogene $H_1^1 : \rho_i < 1$ für $i = 1, \dots, N$ und die heterogene $H_2^1 : \rho_i < 1$ für $i = 1, \dots, N_1$ und $\rho_i = 1$ für $i = N_1 + 1, \dots, N$. Erste stellt die stärkere Bedingung dar. Trifft die Gegenhypothese zu, ist jede Querschnittseinheit stationär. Der Test von Levin, Lin und Chu (2002) verwendet diese Formulierung.

Die ersten Entwicklungen der Einheitswurzeltests treffen die Annahme, dass die einzelnen Zeitreihen querschnittsunabhängig sind. Sie werden Einheitswurzeltests der ersten Generation genannt, da sie zeitlich gesehen vor den anderen Einheits-

wurzeltests entwickelt wurden. Der große Vorteil ist, dass die verschiedenen zentralen Konvergenztheoreme ohne Probleme angewendet werden können und die Grenzverteilungen der Teststatistiken Standard-Verteilungen folgen.

Die vorausgesetzte gruppenweise Unabhängigkeit stellt eine starke Einschränkung für die Paneldaten dar, die in der Praxis in den wenigsten Datensätzen erfüllt ist. In der Literatur der Makroökonomie und der Finanztheorie wird vermehrt auf Beziehungen und Abhängigkeiten zwischen den Zeitreihen verwiesen. Betrachtet man beispielsweise die Wechselkurse verschiedener Länder, so zeigen sich starke querschnittsspezifische Abhängigkeiten durch das Verwenden des Wechselkurses eines Landes als Numeraire. Weiter sind die einzelnen Märkte stark miteinander verbunden. In der Makroökonomie bilden Schocks, wie Ölpreisschocks oder globale Finanzkrisen, die Quelle von Abhängigkeiten zwischen den einzelnen Gruppen. Aber auch in der Mikroökonomie existieren Faktoren, die für Querschnittsabhängigkeiten sprechen, wie Modeerscheinungen, Triebe, oder auch Wirtschaftsrezessionen und -aufschwünge. Vor allem in neueren Artikeln finden sich Ansätze unter Berücksichtigung der gruppenweisen Abhängigkeiten. Sie werden Unit Root Tests der zweiten Generation genannt.

Zu den in der Arbeit durchgeführten Einheitswurzeltests der ersten Generation zählen der Test von Levin, Lin und Chu (2002), Im, Pesaran und Shin (2003), Maddala und Wu (1999) und Choi (2001).

Für die Behandlung der gruppenweisen Korrelation gibt es keine allgemein gültige Vorgehensweise. Das Modellieren der Abhängigkeiten stellt eine große Herausforderung dar.

Eine breite Reihe der Einheitswurzeltests der zweiten Generation behandelt sie durch den Faktoren Ansatz. Dabei werden die Abhängigkeiten zwischen den Querschnittseinheiten als gemeinsame Faktoren modelliert, die berechnet und vor Anwendung des Panel Unit Root Tests eliminiert werden. Mit diesem Ansatz haben sich unter anderen Bai und Ng (2004), Moon und Perron (2004), Pesaran (2007) und Phillips und Sul (2003) beschäftigt.

Chois (2002) Ansatz basiert auf der Verwendung eines Fehler Komponenten Modells. Sie eliminiert sowohl die deterministischen Komponenten als auch die gruppenspezifischen Abhängigkeiten aus den Daten, bevor der Panel Einheitswurzeltest durchgeführt wird.

Eine Alternative bildet die Verwendung von Instrumentenvariablen zur Behand-

lung der gruppenweisen Korrelationen. Chang (2002) und Shin und Kang (2006) verwenden diese Methode.

Breitung und Das (2005) präsentieren eine robuste Dickey Fuller Regression, welche durch Verwenden einer „Pre-Whitening“ Methode die Querschnittsabhängigkeiten behandelt.

Im Folgenden werden die einzelnen UR Tests für zwei Modellarten der deterministischen Komponente durchgeführt: einerseits mit einer Konstante α_{i0} und andererseits mit einer Konstante und einem linearen Trend $\alpha_{i0} + \alpha_{i1}t$.

Prinzipiell gilt, wenn ein Trend in der Testgleichung mitgeschätzt wird, die Daten der Zeitreihe jedoch keinen besitzen, reduziert sich die Signifikanz des Tests. Umgekehrt gilt, wenn die Zeitreihe einen Trend hat, dieser in der Testgleichung nicht berücksichtigt wird, verzerrt sich die Teststatistik in Richtung der Nullhypothese. Es ist üblich die Bruttowertschöpfung in der Makroökonomie auf zwei Arten zu modellieren: Einerseits wird die Zeitreihe als Unit Root-stationär mit stochastischem Trend und andererseits als Trend-stationär mit deterministischem linearen Trend dargestellt, was den beiden Ausprägungen der deterministischen Komponente entspricht.

Die Tabellen beinhalten die ermittelten Teststatistiken, fett geschriebene Werte kennzeichnen das Verwerfen der Nullhypothese zu einem Signifikanzniveau von 5%.

5.2 Einheitswurzeltests der ersten Generation

5.2.1 Der Test von Levin, Lin und Chu (2002)

Bei dem Test von Levin, Lin und Chu (LLC) (2002) [49] handelt es sich im Prinzip um einen gepoolten ADF-Unit Root Test. Die Ordnung der verzögerten Variablen kann dabei für jede Querschnittseinheit verschieden sein.

Zunächst muss für jede Querschnittseinheit die individuelle Ordnung der verzögerten Variablen bestimmt werden. Dazu schlagen LLC eine Methode von Hall (1994) vor. Bei dieser wird eine maximale Ordnung der Verzögerung festgesetzt, sie wird mit p_{max} bezeichnet. Ausgehend von dieser wird im Anschluss eine ADF Regres-

sion mit Ordnung p_{max} (5.3) für jede Gruppe durchgeführt, und die t-Statistik von $\gamma_{p_{max}}$ betrachtet, um zu bestimmen, ob eine geringere Ordnung der verzögerten Variablen ausreicht. Diese t-Statistik ist unter der Nullhypothese standardnormalverteilt. Wenn die t-Statistik kleiner als $-1,645$ ist, wird die Nullhypothese angenommen und $\gamma_{p_{max}} = 0$ gesetzt. Dieser Vorgang wird solange wiederholt, bis die entsprechende Nullhypothese verworfen wird. Es wird sozusagen von einem generellen Modell sequentiell zu einem spezifischen getestet. Die relevante Ordnung der verzögerten Variablen für die i-te Gruppe wird mit p_i bezeichnet.

Es gibt auch andere Möglichkeiten die Ordnung der verzögerten Variablen zu bestimmen, dazu zählen die Kriterien von Akaike (1973), Schwarz (1978) oder Hannan und Quinn (1979). Im Weiteren wird für die Bestimmung der Ordnung der verzögerten Variablen immer die Methode von Hall (1994) verwendet.

Im Anschluss werden für jede Querschnittseinheit zwei Regressionen durchgeführt, um orthogonale Residuen zu konstruieren: Δy_{it} und y_{it-1} werden auf Δy_{it-L} , wobei $L = 1, \dots, p_i$, und die deterministische Komponente α_{it} regressiert. Sie werden mit \hat{e}_{it} und \hat{v}_{it-1} bezeichnet. Um die Heterogenität der Residuen zu kontrollieren, werden diese normalisiert: $e_{it} = \frac{\hat{e}_{it}}{\sigma_{ei}}$ und $v_{it} = \frac{\hat{v}_{it}}{\sigma_{ei}}$, wobei σ_{ei} den Standardfehler der ursprünglichen ADF-Regressionen (5.3) bezeichnet.

Als nächstes wird das langfristige Varianzverhältnis (LFV), σ_{yi} , gruppenweise ermittelt. Unter der Nullhypothese kann das LFV für die i-te Querschnittseinheit wie folgend definiert werden:

$$\sigma_{y_i}^2 = \frac{1}{T-1} \sum_{t=2}^T \Delta y_{it}^2 + 2 \sum_{L=1}^K \omega_{KL} \left[\frac{1}{T-1} \sum_{t=2+L}^T \Delta y_{it} \Delta y_{it-L} \right],$$

wobei $\omega_{KL} = 1 - \frac{L}{K+1}$ die Gewichte des abgeänderten Bartlett Kerns mit K dem Abbruchparameter und L die Ordnung der verzögerten Variablen der i-ten Gruppe sind. Für die Bestimmung von K in der Praxis geben LLC die Formel $K = 3.21T^{\frac{1}{3}}$ an. Für die Ausprägungen mit Konstante bzw. mit Konstante und linearem Trend müssen die Daten vor der Berechnung des LFV Mittelwert bzw. Trend bereinigt werden.

Im Anschluss wird für jede Gruppe das langfristige Varianzverhältnis zur Standardabweichung berechnet: $s_i = \frac{\sigma_{yi}}{\sigma_{ei}}$ und das arithmetische Mittel $S_N = \frac{1}{N} \sum_{i=1}^N s_i$

bestimmt. Alle bisherigen Ergebnisse werden gepoolt, um die Teststatistik

$$t_{\delta} = \frac{\delta}{STD(\delta)} \quad (5.4)$$

zu bestimmen, wobei $\delta = \frac{\sum_{i=1}^N \sum_{t=2+p_i}^T v_{it-1} e_{it}}{\sum_{i=1}^N \sum_{t=2+p_i}^T v_{it-1}^2}$ und $STD(\delta) = \sigma_{\varepsilon} [\sum_{i=1}^N \sum_{t=2+p_i}^T v_{it-1}^2]^{-\frac{1}{2}}$ ist. Mit $\sigma_{\varepsilon}^2 = \frac{1}{NT} \sum_{i=1}^N \sum_{t=2+p_i}^T (e_{it} - \delta v_{it-1})^2$ und $\tilde{T} = T - p - 1$, wobei p das Mittel der Ordnung der verzögerten Variablen ist. Unter der Nullhypothese ist die Teststatistik t_{δ} asymptotisch standardnormalverteilt.

Enthalten die Querschnittseinheiten eine Konstante bzw. eine Konstante und einen linearen Trend, muss die Teststatistik leicht angepasst werden, um die Standardnormalverteilung zu erhalten:

$$t_{\delta}^* = \frac{t_{\delta} - N\tilde{T}S_N\sigma_{\varepsilon}^{-2}STD(\delta)\mu_{mT}}{\sigma_{mT}}. \quad (5.5)$$

Die Werte für die Mittelwert μ_{mT} und die Trend Anpassung σ_{mT} sind auf Seite 14 im Artikel von Levin, Lin und Chu (2002) tabelliert.

5.2.2 Der Test von Im, Pesaran und Shin (2003)

Im, Pesaran und Shin (IPS) (2003) [42] konstruieren ihren Panel Einheitswurzeltest aus dem Mittel individueller ADF Tests.

Der von IPS als "t_bar" bezeichnete Test kann für zwei verschiedene Varianten durchgeführt werden: Die erste, vereinfachte Teststatistik behandelt die Zeitreihen als AR(1)-Prozesse, wobei die Störterme als seriell unkorreliert vorausgesetzt werden. Es werden individuelle DF Tests für jede Einheit (5.2) durchgeführt. Die Teststatistik für die i -te Querschnittseinheit ist dann gegeben durch den t-Quotienten von ϕ_i in der DF Regression von Δx_i auf $\tau = (1, 1, \dots, 1)$ und x_{i-1} . Er wird mit t_i bezeichnet.

Für die zweite Teststatistik dürfen die Störterme seriell korreliert sein, die Zeitreihen werden in diesem Fall durch $AR(p_i)$ -Prozesse modelliert, wobei die Ordnung der verzögerten Variablen p_i für jede Querschnittseinheit verschieden sein kann. Die individuelle Teststatistik wird wie zuvor durch den t-Quotienten von ϕ_i in der Gleichung (5.3) bestimmt.

Für die Ausprägung mit linearem Trend wird die Regression um eine Zeitvariable, welche dem linearen Trend entspricht, erweitert.

Im Anschluss wird das arithmetische Mittel der individuellen Teststatistiken

$$t_bar = \frac{1}{N} \sum_{i=1}^N t_i \quad (5.6)$$

gebildet.

Die Teststatistik

$$Z_{t_bar} = \frac{\sqrt{N}(t_bar - E[t_T])}{\sqrt{Var[t_T]}} \quad (5.7)$$

ist unter der Nullhypothese asymptotisch standardnormalverteilt, wobei die mit Monte Carlo Simulation berechneten Werte für $E[t_T]$ und $Var[t_T]$ im Artikel auf der Seite 60 tabelliert sind. Für die AR(1) Prozesse kommt es für kleine Werte von N und T zu Abweichungen von der Standardnormalverteilung. IPS geben für bestimmte N und T die asymptotischen Werte in der Tabelle auf Seite 61 an.

IPS schlagen für die AR(p) Prozesse abgeänderte Werte für $E[t_T]$ und $Var[t_T]$ vor, diese werden mit der Information, welche in der Ordnung der verzögerten Variablen p_i enthalten ist, bestimmt. Die entsprechende Teststatistik wird im Artikel mit W_{t_bar} bezeichnet:

$$W_{t_bar} = \frac{\sqrt{N}(t_bar - \frac{1}{N} \sum_{i=1}^N E[t_i(p_i)])}{\sqrt{\frac{1}{N} \sum_{i=1}^N Var[t_i(p_i)]}} \quad (5.8)$$

Die Werte für den Erwartungswert und die Varianz finden sich in der Tabelle auf Seite 66 für verschiedene p_i . Sie sind für jede Querschnittseinheit von der individuellen Ordnung der verzögerten Variablen abhängig.

Da die Gegenhypothese heterogen formuliert ist, führt das Ablehnen der Nullhypothese nicht notwendigerweise dazu, dass die Einheitswurzel für jede Querschnittseinheit abgelehnt werden kann.

5.2.3 Das Fisher Test Prinzip

Mit dem von Fisher(1932) entwickelten Prinzip haben sich in Zusammenhang mit Paneldaten Maddala und Wu (1999) [51], sowie Choi (2001) [20] beschäftigt. Maddala und Wu (1999) passen das Fisher Prinzip auf Paneldaten an, Choi(2001)

hingegen entwickelt drei neue Teststatistiken.

Das Fisher Test Prinzip baut auf dem empirischen Signifikanzniveau (P-Wert, Überschreitungswahrscheinlichkeit) eines Tests auf Einheitswurzeln auf. Wenn die Teststatistiken stetig sind, so sind die p-Werte der individuellen Tests, p_i , uniform verteilt und $-2\ln(p_i)$ ist χ^2 -verteilt mit 2 Freiheitsgraden. Damit ist die Gesamtteststatistik

$$P = -2 \sum_{i=1}^N \ln(p_i) \quad (5.9)$$

χ^2 -verteilt mit $2N$ Freiheitsgraden. Wegen dieser Tatsache hat der Test auch den Namen „inverser Chi-Quadrat Test“. Die Ordnung der verzögerten Variablen kann für jede Querschnittseinheit unterschiedlich sein.

Die Gegenhypothese ist wie bei IPS heterogen formuliert. Sie erlaubt, dass einige Querschnittseinheiten stationär sind und andere nicht.

Der für die Durchführung des Fisher Tests benötigte p-Wert muss nicht durch eine ADF Regression ermittelt werden. Es kann irgendein Test auf Einheitswurzeln verwendet werden mit dem der p-Wert bestimmt werden kann. Das ist ein großer Vorteil dieser Testmethode. Außerdem benötigt man zur Durchführung kein ausgeglichenes Panel.

Choi (2001) modifiziert das ursprüngliche Fisher Prinzip so, dass für endliches N die Teststatistik unter der Nullhypothese asymptotisch standardnormalverteilt ist. Die entsprechende Teststatistik des „ P_m -Tests“ lautet:

$$P_m = \frac{1}{2\sqrt{N}} \sum_{i=1}^N (-2\ln(p_i) - 2) = -\frac{1}{\sqrt{N}} \sum_{i=1}^N (\ln(p_i) + 1). \quad (5.10)$$

Die Gültigkeit für endliches N folgt aus $\mathbf{E}[-2\ln(p_i)] = 2$ und $\mathbf{Var}[-2\ln(p_i)] = 4$. Die Nullhypothese wird für große positive Werte der Teststatistik verworfen.

Als zweites entwickelt sie den sogenannten „inversen Normaltest“ oder auch „Z-Test“. Wie sein Name bereits verrät, beruht dieser auf der Tatsache, dass $0 \leq p_i \leq \Phi^{-1}(p_i)$ eine standardnormalverteilte Zufallsvariable ist. Die Teststatistik

lautet:

$$Z = \frac{1}{\sqrt{N}} \sum_{i=1}^N \Phi^{-1}(p_i). \quad (5.11)$$

Unter der Nullhypothese ist der Z-Test asymptotisch standardnormalverteilt. Die Nullhypothese wird zu einem Signifikanzniveau von 5% verworfen, wenn die Teststatistik kleiner als $-1,645$ ist.

Die Ergebnisse von Monte Carlo Simulationen haben gezeigt, dass der Z-Test bereits für kleinere Panels, das heißt eine geringe Anzahl an Querschnittseinheiten und Zeitperioden, exakte Ergebnisse liefert. Beim Bilden der Teststatistik treten kaum Verzerrungen auf.

Die dritte Teststatistik ist ein logarithmierter Test:

$$L = \sum_{i=1}^N \ln\left(\frac{p_i}{1-p_i}\right). \quad (5.12)$$

Der „L-Test“ weist das gleiche asymptotische Verhalten wie der Z-Test auf.

5.2.4 Vergleich der Tests

Grundsätzlich sind nur der Test von Im, Pesaran und Shin (2003) und die Fisher Tests direkt miteinander vergleichbar. Bei beiden wird die Teststatistik durch Kombination von verschiedenen individuellen Teststatistiken gebildet, wobei bei Fisher die p-Werte von individuellen ADF Tests und bei IPS die einzelnen Teststatistiken selbst zusammengeführt werden. Für die Fisher Statistiken können auch p-Werte anderer individueller Tests auf Einheitswurzeln verwendet werden. Die Teststatistik von IPS benötigt das Mittel und die Varianz der t-Statistiken zur Bildung, damit ist IPS ein parametrischer Test. Fisher hingegen ist ein nicht-parametrischer Test. Beim Fisher Testprinzip handelt es sich um einen exakten und bei IPS um einen asymptotischen Test.

Die Teststatistik von Levin, Lin und Chu (2002) hingegen wird durch eine gepoolte Regression gebildet. Besteht kein Grund für das Poolen der Daten so liefert der LLC Test keine brauchbaren Ergebnisse.

Die Tests haben zwar dieselbe Nullhypothese, unterscheiden sich aber zu dem Testprinzip von LLC in Bezug auf die Gegenhypothese, welche bei LLC homogen und bei den anderen heterogen ist. Die homogene Gegenhypothese bei LLC stellt eine starke Einschränkung dar, da sie für alle Querschnittseinheiten Stationarität fordert. Laut Maddala und Wu(1999) kann diese in keinem interessanten empirischen Fall eingehalten werden.

Maddala und Wu (1999) führen in ihrem Artikel Monte Carlo Simulationen für den Vergleich des Fisher Prinzips, des Tests von LLC und IPS durch.

Wenn die Paneldaten als eine Mischung von stationären und nicht stationären Zeitreihen modelliert werden, hat das Fisher Prinzip die größte Macht zwischen Null- und Gegenhypothese zu unterscheiden.

Wenn die Fehler nicht korreliert sind, liefert der t_{bar} -Test die besten Ergebnisse. Auch der Fisher Test schneidet in diesem Fall besser als der t_{δ} -Test ab.

Prinzipiell haben ihre Simulationen gezeigt, dass der Fisher Test allgemein die besten Ergebnisse liefert.

Chois (2001) Vergleich des t_{bar} - und Fisher Tests zeigt, dass beide exakte Ergebnisse liefern. Die Macht der Tests steigt mit der Anzahl an Querschnittseinheiten. Sie fällt, wenn ein linearer Trend in der Regression beinhaltet ist.

Alle Tests können serielle Korrelation und Heteroskedastizität der Fehler behandeln, tritt jedoch Korrelation zwischen den Querschnittseinheiten auf, versagen sie alle.

Zunächst wurde versucht dieses Problem durch Bootstrapping der Einheitswurzeltests der ersten Generation zu umgehen. Maddala und Wu (1999) beschäftigen sich mit diesem Ansatz. In der Praxis sind die Bootstrapping Methoden für Panels nur schwer zu implementieren. Außerdem verringern die Tests basierend auf Bootstrapping zwar die Größenverzerrung der Einheitswurzeltests, wenn Querschnittskorrelation vorliegt, eliminieren diese aber nicht.

Choe und Chue (2007) verwenden sogenanntes „Subsampling“, bei diesem wird der Paneldatensatz in Blöcke mit geringerer Anzahl an Zeitperioden unterteilt. Für jeden dieser Blöcke werden die Einheitswurzeltests der ersten Generation durchgeführt und Verteilungsfunktionen generiert.

In den letzten Jahren wurden neue Einheitswurzeltests entwickelt, die mit diesem Problem auch ohne Bootstrapping Methoden fertig werden. Diese werden in den

nächsten Abschnitten untersucht.

5.2.5 Die NAMEA Testergebnisse

Die präsentierten Einheitswurzeltests der ersten Generation werden nun auf die NAMEA Daten angewendet. Es werden die Teststatistiken von Levin, Lin und Chu (2002) (t_δ), von Im, Pesaran und Shin (2003) (t_{bar}) und das Fisher Prinzip (P), sowie die Z-Teststatistik von Choi (2001) für die Modelle mit einer Konstante in der Tabelle 5.1 und die Modelle mit Konstante und linearem Trend in der Tabelle 5.2 präsentiert.

Der Test von IPS wird für zwei Varianten durchgeführt, einerseits die vereinfachte Variante mit AR(1)-Prozessen ($t_{bar_{AR(1)}}$) und andererseits jene mit individueller Ordnung der verzögerten Variablen ($t_{bar_{AR(p_i)}}$), um serielle Korrelation der Fehler zu behandeln. Die benötigten Werte von $E[t_T]$ und $Var[t_T]$ werden für die AR(1)-Prozesse der Tabelle auf Seite 60 und für die $AR(p_i)$ -Prozesse der Tabelle auf Seite 66 mit $T = 10$ aus dem Artikel von Im, Pesaran und Shin (2003) entnommen.

Die individuelle Ordnung der verzögerten Variablen wird für die einzelnen Tests mit der Methode von Hall (1004) bestimmt, wobei mit einer maximalen Ordnung von vier verzögerten Variablen gestartet wird.

Die kritischen Werte der Teststatistiken zu einem Signifikanzniveau von 5% sind für den t_δ - und den Z-Test $-1,645$ und für den P-Test mit 36 Freiheitsgraden $50,9985$. Für den Test von IPS lauten die kritischen Werte zu einem Signifikanzniveau von 5% für die AR(1)-Prozesse im Modell mit Konstante $-1,95$ mit $N = 15$ und $T = 10$ und im Modell mit Konstante und linearem Trend $-2,63$, sowie für die $AR(p_i)$ -Prozesse $-1,645$.

Die Tabelle 5.1 der Modelle mit Konstante zeigt, dass für die Bruttowertschöpfung dividiert durch die Erwerbstätigen, deren Quadrat und dritte Potenz, sowie die Luftschadstoffemission Stickoxid drei der fünf Nullhypothesen der Unit Root-Stationarität angenommen werden. Bei der Betrachtung des Produktionswertes pro Erwerbstätigen, ist zu erkennen, dass für $\log(\frac{Prod}{EW})$, $\log(\frac{Prod}{EW})^2$ und $\log(\frac{Prod}{EW})^3$ der Großteil der Tests für die Existenz einer Einheitswurzel entscheidet. Auch für Kohlendioxid werden alle Nullhypothesen der Teststatistiken mit Ausnahme jener von IPS mit $AR(p_i)$ -Prozessen angenommen. Hingegen wird die Nullhypothese aller

Tabelle 5.1: Die Testergebnisse im Modell mit Konstante

Variable	t_δ	$t_bar_{AR(1)}$	$t_bar_{AR(p_i)}$	P	Z
$\log(\frac{BW}{EW})$	1,7842747	2,8440336	-5,2807221	55,4041	5,14878
$\log(\frac{BW}{EW})^2$	1,9774511	2,9847260	-5,1237353	54,422315	5,3222869
$\log(\frac{BW}{EW})^3$	2,1688659	3,1235451	-4,9662530	53,328647	5,4978619
$\log(\frac{Prod}{EW})$	-0,96152749	2,9936365	-6,0730182	38,822	3,4878411
$\log(\frac{Prod}{EW})^2$	-0,50844750	3,0770972	-5,7724890	37,949384	3,7067869
$\log(\frac{Prod}{EW})^3$	-0,22273913	3,1567380	-5,6122049	37,353762	3,8744405
$\log(\frac{CO}{EW})$	-8,5613992	0,19241541	-9,3205050	269,154	-2,71563
$\log(\frac{CO2}{EW})$	1,9532434	0,59558562	-7,7724406	42,1795	2,7067647
$\log(\frac{CH4}{EW})$	-8,2772371	1,3206249	-9,2841376	149,992	-0,83042
$\log(\frac{SO2}{EW})$	-7,4447712	-2,2642096	-10,655229	210,289	-4,2861094
$\log(\frac{NOx}{EW})$	2,6647570	-1,0133617	-6,0425838	57,5914	0,76417677

Tabelle 5.2: Die Testergebnisse im Modell mit Konstante und linearem Trend

Variable	t_δ	$t_bar_{AR(1)}$	$t_bar_{AR(p_i)}$	P	Z
$\log(\frac{BW}{EW})$	-3,0738719	-3,6230746	-19,637498	409,354	-
$\log(\frac{BW}{EW})^2$	-13,681054	-3,4833828	-32,306545	139,53224	-
$\log(\frac{BW}{EW})^3$	-68,303389	-3,3447796	-96,744445	135,56595	-
$\log(\frac{Prod}{EW})$	-2,6169755	-4,0064008	-13,254286	92,4642	-1,5950026
$\log(\frac{Prod}{EW})^2$	-2,5103109	-3,9890163	-13,241389	95,394798	-1,7137777
$\log(\frac{Prod}{EW})^3$	-2,8239483	-3,9731417	-13,254282	37,353762	-2,7358566
$\log(\frac{CO}{EW})$	-15,031271	-3,4477847	-12,058214	611,174	-10,5865
$\log(\frac{CO2}{EW})$	-60,570854	-4,6538397	-21,404549	428,636	-10,507533
$\log(\frac{CH4}{EW})$	-13,804406	-1,2866824	-12,856544	378,651	-6,6346
$\log(\frac{SO2}{EW})$	-3,3700583	-4,2065022	-10,982984	348,092	-6,4826613
$\log(\frac{NOx}{EW})$	1,6705327	-4,5308603	-14,770287	324,172	-4,5644291

Teststatistiken für Schwefeldioxid verworfen. Auch für Kohlenmonoxid werden vier der fünf Nullhypothesen verworfen. Bei Methan entscheiden zwei der fünf Teststatistiken für die Existenz einer Einheitswurzel.

In der Tabelle 5.2 sind die Testergebnisse für die Modelle mit Konstante und linearem Trend tabelliert. Für die Bruttowertschöpfung pro Erwerbstätigen und ihre höheren Potenzen kann der Z-Test nicht durchgeführt werden, da die p-Werte der individuellen Teststatistiken sehr nahe bei 1 sind und daher die Inverse des p-Werts nicht berechnet werden kann. Für die verbleibenden vier Teststatistiken wird die Nullhypothese der Unit Root-Stationarität für die Variable Bruttowertschöpfung pro Erwerbstätigen und ihre höheren Potenzen verworfen. Für die ökonomische Variable Produktionswert dividiert durch die Anzahl der Erwerbstätigen, ihr Quadrat und ihre dritte Potenz muss die Nullhypothese aller Teststatistiken mit Ausnahme des Z-Tests für $\log\left(\frac{Prod}{EW}\right)$ abgelehnt werden, wobei zu einem Signifikanzniveau von 10% auch diese Nullhypothese abgelehnt wird. Bei der Anwendung der Tests auf die Luftschadstoffemissionen werden für Kohlendioxid, Kohlenmonoxid und Schwefeldioxid alle Nullhypothesen und für Methan und Stickoxid vier der fünf Nullhypothesen verworfen.

5.3 Einheitswurzeltests der zweiten Generation - Der Faktoren Ansatz

Das Faktoren Modell zur Untersuchung der Stationarität eines Paneldatensatzes setzt sich aus folgenden Komponenten zusammen:

$$x_{it} = \alpha_i + x_{it}^0 \quad (5.13)$$

$$x_{it}^0 = \rho_i x_{it-1}^0 + u_{it} \quad (5.14)$$

und der unbeobachtbare Fehlerterm u_{it} :

$$u_{it} = \lambda_i' f_t + e_{it}, \quad (5.15)$$

wobei die beobachtbaren x_{it} durch eine deterministische Komponente α_i und einen autoregressiven Prozess x_{it}^0 generiert werden.

Der Fehlerterm repräsentiert die Faktorenstruktur und modelliert so die Abhängig-

keiten unter den einzelnen Querschnittseinheiten. Er setzt sich aus e_{it} den idiosynkratischen, individuellen oder auch einheitenspezifischen Schocks, sowie f_t dem $K \times 1$ -Vektor der unbeobachtbaren gemeinsamen Faktoren mit λ_i den nichtzufälligen Faktorenladungskoeffizienten zusammen. Diese bestimmen wie die einzelnen Querschnittseinheiten auf die gemeinsamen Faktoren unterschiedlich reagieren. Ein Faktoren Modell mit N Querschnittseinheiten hat N idiosynkratische Komponenten aber nur wenige gemeinsame Faktoren.

Die Standardannahmen über die einzelnen Komponenten sind:

1. Die gemeinsamen Faktoren f_t werden durch einen linearen stationären Prozess $f_t = \sum_{j=1}^{\infty} c_j w_{t-j}$ generiert, wobei die w_t als unabhängig identisch verteilt mit Mittel Null und konstanter Varianz modelliert werden.
Die Kovarianzmatrix von f_t ist positiv definit, dadurch können die nicht stationären gemeinsamen Faktoren kointegriert sein.
2. Die idiosynkratischen Komponenten werden als lineare stationäre Prozesse modelliert: $e_{it} = \sum_{j=0}^{\infty} d_{ij} v_{it-j}$. Die v_{it} sind unabhängig identisch verteilt mit Mittel Null und konstanter Varianz.
Sie sind seriell über die Querschnittseinheiten unkorreliert. Das garantiert, dass die Kovarianzmatrix block-diagonal ist und schließt Kointegration zwischen den idiosynkratischen Komponenten aus. Außerdem wird gefordert, dass gilt: $\inf_i \sum_{j=0}^{\infty} d_{ij} > 0$. Das garantiert, dass jedes Element der Diagonale der Kovarianzmatrix nicht Null ist.
Die Varianz, das langfristige Varianzverhältnis, sowie die einseitige Kovarianz existieren für alle idiosynkratischen Komponenten und haben von Null verschiedene Mittel über die Querschnittseinheiten.
3. Es existiert zumindest ein gemeinsamer Faktor. Die Anzahl der gemeinsamen Faktoren ist beschränkt.
4. Wenn $N \rightarrow \infty$, dann gilt $N^{-1} \sum_{i=1}^N \lambda_i \lambda_i' \rightarrow \Sigma_{\lambda}$ mit Σ_{λ} einer $k \times k$ positiv definiten Matrix, wobei k die Anzahl der gemeinsamen Faktoren ist.
Wenn $T \rightarrow \infty$, dann gilt $T^{-1} \sum_{t=1}^T f_t f_t' \rightarrow \Sigma_f > 0$.
Damit wird garantiert, dass jeder Faktor zumindest zu einem x_{it} zugehörig ist, jedoch müssen nicht alle Querschnittseinheiten zu allen Faktoren gehören.

5. e_{it} , f_t und λ_i sind drei unabhängig verteilte Gruppen von Variablen.

Diese Annahmen beziehen sich auf das Modell von Moon und Perron (2004).

5.3.1 Die Informationskriterien

Zur Durchführung der Unit Root Tests mit dem Faktoren Ansatz wird die Anzahl der gemeinsamen Faktoren benötigt. Diese ist in der Praxis unbekannt und kann durch sogenannte Informationskriterien bestimmt werden. Die Informationskriterien wurden ursprünglich von Mallows (1973) für Zeitreihen entwickelt. Bai und Ng (2002) erweitern das Prinzip für Paneldatensätze.

Es werden verschiedene Informationskriterien präsentiert. Die erste Variante stammt aus dem Artikel von Bai und Ng (2002), bei dieser werden die Informationskriterien auf die Differenzen der Variablen angewendet. Moon und Perron (2004) wenden dieselben Kriterien auf die Residuen einer gepoolten Regression an. Bai (2004) wendet die Informationskriterien auf die Niveaus der Variablen an.

Prinzipiell wird ein Informationskriterium wie folgend modelliert:

Zuerst werden für eine Zahl $k < \min\{T, N\}$ die Schätzer für λ^k und F^k durch Lösen von:

$$V(k) = \min_{\Lambda, F^k} (NT)^{-1} \sum_{i=1}^N \sum_{t=1}^T (x_{it} - \lambda_i^k f_t^k)^2 \quad (5.16)$$

unter der Normalisierung $\frac{F^k F^k}{T} = I_k$ ermittelt. Damit ist das Minimierungsproblem äquivalent zur Maximierung von $tr(F^k (X X') F^k)$, wobei X die $T \times N$ -Matrix der Daten und F^k die $T \times k$ -Matrix der gemeinsamen Faktoren ist. tr kennzeichnet die Spur der Matrix. Die geschätzte Faktorenmatrix \tilde{F}^k ist dann \sqrt{T} -mal die Eigenvektoren, welche zu den k größten Eigenwerten von der $T \times T$ -Matrix $X X'$ gehören. Die zugehörige Matrix der Faktorenladungen ist: $\tilde{\Lambda}^k = \frac{\tilde{F}^k X}{T}$.

Auch wenn die Quadratsumme der Residuen von $V(k)$ eindeutig ist, ist das Minimierungsproblem (5.16) nicht eindeutig lösbar. Unter der Normalisierung $\frac{\Lambda^k \Lambda^k}{N} = I_k$, sei die Lösung gegeben durch \bar{F}^k und $\bar{\Lambda}^k$. Dabei ist $\bar{\Lambda}^k$ durch \sqrt{N} -mal die Eigenvektoren, welche zu den k größten Eigenwerten der $N \times N$ -Matrix $X' X$ gehören, gegeben. Die zugehörigen gemeinsamen Faktoren sind dann: $\bar{F}^k = \frac{X \bar{\Lambda}^k}{N}$. Die zweite Variante ist für $T > N$ weniger rechenintensiv, während die erste Variante für

$T < N$ ist.

Bei dieser Minimierung handelt es sich natürlich um die Methode der Hauptkomponenten.

Sei $V(k, \widehat{F}^k)$ die Varianz der idiosynkratischen Komponente von (5.16), wenn k Faktoren ermittelt wurden. Es werden nun Kriterien gesucht, sodass

$$PC(k) = V(k, F^k) + kg(N, T) \quad (5.17)$$

konsistent r , die wahre Anzahl der gemeinsamen Faktoren, ermitteln kann, wobei $g(N, T)$ eine Straffunktion ist. Sei k_{max} eine positive Zahl, sodass gilt $r < k_{max}$, dann wird die wahre Anzahl der gemeinsamen Faktoren durch:

$$r = \arg \min_{0 \leq k \leq k_{max}} PC(k) \quad (5.18)$$

bestimmt.

Die Grundidee der Paneldateninformationskriterien ist für diese Straffunktion sowohl N als auch T miteinzubeziehen, wobei es verschiedene Ausprägungen der Straffunktion gibt. Für eine Straffunktion müssen die folgenden Annahmen erfüllt sein: $g(N, T) \rightarrow 0$ und $\min\{N, T\}g(N, T) \rightarrow \infty$ wenn N und T gegen unendlich laufen.

Die präsentierten Informationskriterien lauten:

$$PC_1(k) = V(k, \widehat{F}^k) + k\sigma^2 \left(\frac{N+T}{NT} \right) \ln \left(\frac{NT}{N+T} \right) \quad (5.19)$$

$$PC_2(k) = V(k, \widehat{F}^k) + k\sigma^2 \left(\frac{N+T}{NT} \right) \ln(C^2(N, T)) \quad (5.20)$$

$$PC_3(k) = V(k, \widehat{F}^k) + k\sigma^2 \left(\frac{\ln(C^2(N, T))}{C^2(N, T)} \right) \quad (5.21)$$

$$AIC_3(k) = V(k, \widehat{F}^k) + k\sigma^2 \left(2 \frac{N+T-k}{NT} \right) \quad (5.22)$$

$$BIC_3(k) = V(k, \widehat{F}^k) + k\sigma^2 \left(\frac{N+T-k}{NT} \right) \ln(NT), \quad (5.23)$$

wobei σ^2 ein Schätzer für $(NT)^{-1} \sum_{i=1}^N \sum_{t=1}^T E[e_{it}]^2$ ist und $C^2(N, T) = \min\{N, T\}$. In der Praxis wird σ^2 durch $V(k_{max}, F^{k_{max}})$, die Varianz der idiosynkratischen Komponente mit der maximalen Anzahl an gemeinsamen Faktoren, ersetzt.

Bei den beiden letzten Kriterien handelt es sich um abgeänderte Versionen der eigentlichen Informationskriterien von Mallows (1973) für Zeitreihen.

Diese können auf die Differenzen oder die Residuen der Variablen angewendet werden, das bedeutet, dass x_{it} in (5.16) durch Δx_{it} oder \hat{u}_{it} ersetzt wird.

Die Informationskriterien aus Bai (2004) werden auf die Niveaus der Variablen angewendet.

Sei $\alpha_T = \frac{T}{4 \log \log(T)}$:

$$IPC_1(k) = V(k, \hat{F}^k) + k\sigma^2 \alpha_T \left(\frac{N+T}{NT}\right) \ln\left(\frac{NT}{N+T}\right) \quad (5.24)$$

$$IPC_2(k) = V(k, \hat{F}^k) + k\sigma^2 \alpha_T \left(\frac{N+T}{NT}\right) \ln(C^2(N, T)) \quad (5.25)$$

$$IBIC_3(k) = V(k, \hat{F}^k) + k\sigma^2 \alpha_T \left(\frac{N+T-k}{NT}\right) \ln(NT). \quad (5.26)$$

Im Gegensatz zu den anderen, bestimmen diese nur die nicht stationären gemeinsamen Faktoren.

5.3.2 Das Testprinzip von Moon und Perron (2004) und Phillips und Sul (2003)

Der Test von Moon und Perron (2004) [57] baut auf dem präsentierten Faktoren Modell auf, wobei die Anzahl der gemeinsamen Faktoren im Allgemeinen nicht bekannt ist. Phillips und Sul (2003) [67] hingegen betrachten ein Modell mit nur einem gemeinsamen Faktor. Die Daten werden mit dem gleichen Prinzip transformiert, jedoch wird Transformationsmatrix unterschiedlich gebildet.

Prinzipiell wird die Nullhypothese, dass alle Zeitreihen der Querschnittseinheiten eine Einheitswurzel haben, gegen die Alternativhypothese getestet, dass zumindest eine Zeitreihe stationär ist, wobei die Teststatistik nach Abzug der gemeinsamen Faktoren (des gemeinsamen Faktors) ermittelt wird. Trifft die Nullhypothese zu, werden die beobachteten Daten durch die integrierten gemeinsamen Faktoren (den integrierten gemeinsamen Faktor), sowie die idiosynkratischen Komponenten beeinflusst.

Würden die gemeinsamen Faktoren (der gemeinsame Faktor) bei der Durchführung des Tests gegenwärtig sein, würde die Nullhypothese der gepoolten Tests, welche auf der Annahme der gruppenweisen Unabhängigkeit beruht, zu häufig verworfen werden. Außerdem kann so das bei den Einheitswurzeltests der ersten Generation übliche normalverteilte Limit garantiert werden.

Um die Daten von den gemeinsamen Faktoren (dem gemeinsamen Faktor) zu bereinigen wird eine orthogonale Projektion auf den Raum der Faktorenladungen durchgeführt. Dazu müssen zunächst die gemeinsamen Faktoren (der gemeinsame Faktor) und die zugehörigen Faktorladungen bestimmt werden. Bei der Bestimmung unterscheiden sich der Test von Moon und Perron (2004) und Phillips und Sul (2003).

Moon und Perron (2004)

Bei Moon und Perron (2004) werden diese durch die Methode der Hauptkomponenten angewendet auf den Fehlerterm ermittelt. Da der Fehlerterm nicht beobachtbar ist, werden die Residuen einer gepoolten Regression verwendet:

$$\hat{u}_{it} = x_{it} - \hat{\rho}x_{it-1}, \quad (5.27)$$

wobei $\hat{\rho} = \frac{tr(X'_{-1}X)}{tr(X'_{-1}X_{-1})}$ ist. X bezeichnet die Matrix der beobachtbaren Daten, sowie X_{-1} die um eine Zeitperiode verzögerte Matrix.

Um die Anzahl der relevanten gemeinsamen Faktoren r zu bestimmen, werden die in Bai und Ng (2002) entwickelten Informationskriterien für Paneldatensätze auf die Residuen angewendet. Moon und Perron (2004) empfehlen das BIC_3 -Kriterium, da es auch für Panels mit einer geringen Anzahl an Querschnittseinheiten und Zeitperioden die Faktorenanzahl genau bestimmen kann.

Hat man das „wahre r “ gefunden werden die Daten durch Verwendung der Projektionsmatrix $Q_f = I - \hat{\lambda}_r(\hat{\lambda}'_r \hat{\lambda}_r)\hat{\lambda}'_r$, wobei $\hat{\lambda}_r$ die Matrix der Faktorenladungen gebildet mit der „wahren“ Anzahl an Faktoren ist, transformiert:

$$x_{it}Q_f = x_{it-1}Q_f + e_{it}Q_f. \quad (5.28)$$

I bezeichnet die Einheitsmatrix.

Im Anschluss kann der gepoolte Schätzer

$$\hat{\rho}_{pool} = \frac{tr(X_{-1}Q_fX') - NT\gamma_e}{tr(X_{-1}Q_fX'_{-1})} \quad (5.29)$$

gebildet werden. $\gamma_e = \frac{1}{N} \sum_{i=1}^N \gamma_{ei}$ bezeichnet das Mittel der einseitigen langfristigen Varianz von $\hat{e}_{it} = \hat{u}_{it}Q_f$, der durch Q_f transformierten idiosynkratischen Komponenten. Bei $\hat{\rho}_{pool}$ handelt es sich im Prinzip um einen modifizierten gepoolten OLS-Schätzer der um die gemeinsamen Faktoren bereinigten Daten.

Um die Nullhypothese zu testen, schlagen Moon und Perron (2004) die beiden

folgenden Teststatistiken vor:

$$t_a = \frac{\sqrt{NT}(\hat{\rho}_{pool} - 1)}{\sqrt{2\frac{\hat{\phi}_e^4}{\hat{\omega}_e^4}}} \quad (5.30)$$

$$t_b = \sqrt{NT}(\hat{\rho}_{pool} - 1) \sqrt{\frac{1}{NT^2} \text{tr}(X_{-1} Q_f X'_{-1}) \frac{\hat{\omega}_e^2}{\hat{\phi}_e^4}}. \quad (5.31)$$

$\hat{\omega}_e^2$ bezeichnet das Querschnittsmittel der langfristigen Varianz der idiosynkratischen Komponenten \hat{e}_{it} und $\hat{\phi}_e^4$ das Querschnittsmittel der quadratischen langfristigen Varianz. Unter der Nullhypothese folgen die beiden Teststatistiken asymptotisch einer Standardnormalverteilung.

Beide Teststatistiken eignen sich nicht, wenn das Modell um eine Konstante oder um eine Konstante und einen linearen Trend erweitert wird.

Für diese Modelle bleibt zwar die Bildung der Projektionsmatrix gleich, jedoch werden die Daten vor Bildung des gepoolten Schätzers Mittelwert bzw. Trend bereinigt:

$$\hat{\rho}_{pool}^H = \frac{\text{tr}(X_{-1}^H Q_f X_{-1}^H) - NT v_{bias}}{\text{tr}(X_{-1}^H Q_f X_{-1}^H)}. \quad (5.32)$$

X^H kennzeichnet die Mittelwert bzw. Trend bereinigten Daten.

Da die Teststatistik in diesen Fällen verzerrt ist, muss v_{bias} abgezogen werden. Dieser wird durch $v_{bias} = \mathbf{E}\left(\frac{\text{tr}(\hat{E}_{-1} \hat{e}')}{NT}\right)$ bestimmt, wobei \hat{E}_{-1} die um eine Einheit verzögerte untere Dreiecksmatrix des Schätzers für die idiosynkratischen Komponenten bezeichnet. Die Verzerrung entsteht durch die Abhängigkeiten der bereinigten Daten zwischen \hat{E}_{-1} und \hat{e} .

Für diese Modelle schlagen Moon und Perron (2004) die Teststatistik

$$t_{pool}^H = \sqrt{\text{tr}(X_{-1}^H Q_f X_{-1}^H)} (\hat{\rho}_{pool}^H - 1) \quad (5.33)$$

vor. Sie ist asymptotisch normalverteilt mit Mittelwert 0 und Varianz

$\lim_{N,T} \mathbf{E}\left(\frac{\sum_{i=1}^N \sum_{t=1}^T \hat{e}_{it-1} \hat{e}_{it} - v_{bias}}{NT}\right)$, wobei der Nenner eine Brown'sche Bewegung ist.

Moon und Perron haben gezeigt, dass die Teststatistik mit deterministischer Komponente in einer $\frac{1}{NT}$ -Umgebung der Null keine signifikanten Ergebnisse erzielt. Sie empfehlen daher die Teststatistik in der Praxis mit Vorsicht zu gebrauchen.

Phillips und Sul (2003)

Phillips und Sul (2003) verwenden eine Momenten-basierte Methode um die zuvor definierte Projektionsmatrix Q_f zu bestimmen.

Die Prozedur zur Bestimmung von Q_f lautet im Detail:

Als erstes wird die Momentenmatrix der Differenzen bestimmt: $M_T = \frac{1}{T} \sum_{t=1}^T \hat{u}_t \hat{u}_t'$, wobei \hat{u}_t wie zuvor die Residuen einer gepoolten OLS-Schätzung bezeichnet. Diese ist ein Schätzer für die Kovarianzmatrix der Fehler, welche sich aus $V_u = \Sigma + \delta \delta'$ zusammensetzt.

δ und Σ werden durch Optimierung einer Momenten-basierten Methode geschätzt: $(\hat{\delta}, \hat{\Sigma}) = \arg \min_{\delta, \Sigma} tr[(M_T - \Sigma - \delta \delta')(M_T - \Sigma - \delta \delta)']$. Diese kann mit den folgenden Iterationen gelöst werden: $\delta^{(r)} = \frac{(M_T \delta^{(r-1)} - \Sigma \delta^{(r-1)'})}{\delta^{(r-1)' \delta^{(r-1)}}$ und $\sigma_i^{(r)2} = M_{Tii} - \delta_i^{(r)2}$.

Das Anwenden dieser Prozedur reduziert die Dimension der Querschnittseinheiten um eine Einheit.

Die Schätzer von $\hat{\delta}$ und $\hat{\Sigma}$ werden dann verwendet um $\hat{\delta}_\perp$ und $Q_f = (\hat{\delta}_\perp' \hat{\Sigma} \hat{\delta}_\perp)^{-1/2} \hat{\delta}_\perp'$ zu konstruieren. $\hat{\delta}_\perp$ kann durch die Eigenvektoren der Projektionsmatrix $P_\delta = I - \hat{\delta}(\hat{\delta}'\hat{\delta})^{-1}\hat{\delta}'$ bestimmt werden.

Durch die Transformation der Daten durch Q_f werden diese querschnittsunabhängig und es können alle Teststatistiken der Einheitswurzeltests der ersten Generation zur Untersuchung der Stationarität verwendet werden.

Phillips und Sul (2003) schlagen die Verwendung des folgenden Tests vor:

$$G_{OLS}^{++} = \frac{1}{\sqrt{N} \sigma_\zeta} \sum_{i=1}^{N-1} \left[\frac{\rho_i^+ - 1}{\sigma_{\rho_i^+}} - \mu_\zeta \right], \quad (5.34)$$

wobei ρ_i^+ der Schätzer für die i-te Querschnittseinheit in der Gleichung (5.1) angewendet auf die transformierten Daten ist. $\sigma_{\rho_i^+}$ bezeichnet die Standardfehler der Regressionen. μ_ζ und σ_ζ^2 bezeichnen den Mittelwert und die Varianz der Statistik $\frac{\rho_i^+ - 1}{\sigma_{\rho_i^+}}$. Unter der Nullhypothese ist die Teststatistik G_{OLS}^{++} asymptotisch standardnormalverteilt.

Sie präsentieren weiter eine ähnliche Teststatistik, welche statt auf ρ_i^+ auf unverzerrten Schätzern basiert. Diese werden unter Verwendung einer Medianfunktion bestimmt. Die Teststatistik weist dasselbe asymptotische Verhalten wie G_{OLS}^{++} auf. Außerdem wird empfohlen die Teststatistiken von Choi (2001) zu verwenden, welche durch Kombination der individuellen p-Werte gebildet werden.

5.3.3 Die Tests von Bai und Ng (2004)

Bai und Ng (2004) betrachten das allgemeinste Faktoren Modell in Bezug auf Paneldaten. Dazu wird das Panel Faktoren Modell leicht abgeändert:

$$x_{it} = \alpha_i + \lambda_i' F_t + e_{it}. \quad (5.35)$$

α_i ist die deterministische Komponente und $\lambda_i' F_t$ bzw. e_{it} stellen wie zuvor die gemeinsamen bzw. individuellen Effekte dar.

Diese Veränderung erlaubt Bai und Ng die gemeinsamen Faktoren direkt zu betrachten und die Stationarität der gemeinsamen Faktoren und der idiosynkratischen Komponente getrennt und voneinander unabhängig zu untersuchen. Bai und Ng nennen ihren Ansatz daher „PANIC - Panel Analysis of Nonstationarity in the Idiosyncratic and Common components“.

Im Gegensatz zum Test von Moon und Perron (2004) werden nicht nur die idiosynkratischen Komponenten nach Abzug der gemeinsamen Faktoren auf Nicht-Stationarität untersucht, sondern auch die gemeinsamen Faktoren. Der untersuchte Paneldatensatz ist damit nicht stationär, wenn die individuelle Komponente und/oder mindestens ein gemeinsamer Faktor nicht stationär ist.

Zur Bestimmung der gemeinsamen Faktoren werden nicht die Residuen verwendet, sondern die Differenzen der Zeitreihen. Dieser Unterschied garantiert, dass die gemeinsamen Faktoren und die idiosynkratischen Komponenten konsistent geschätzt werden können, egal welche dynamischen Eigenschaften die wahren F_t und e_{it} aufweisen. Sind sie integriert der Ordnung 1, ist ihre erste Differenz stationär, sind sie hingegen stationär, ist ihre erste Differenz immer noch stationär. Die Überdifferenzierung im zweiten Fall wird durch eine Anpassung ausgeglichen. Eventuelle Probleme beim Durchführen der Tests werden so verhindert.

Sei $y_{it} = \Delta x_{it}$, $f_t = \Delta F_t$ und $z_{it} = \Delta e_{it}$. Um die gemeinsamen Faktoren \hat{f}_t und die Faktorladungen $\hat{\lambda}_i$ zu bestimmen, wird auf die Matrix YY' die Methode der Hauptkomponenten angewendet, wobei Y die $(T-1) \times N$ -Matrix der Daten ist. Dabei entspricht $\hat{f} = (\hat{f}_2, \hat{f}_3, \dots, \hat{f}_T)$ den mit $\sqrt{T-1}$ multiplizierten r Eigenvektoren, welche zu den r größten Eigenwerten von YY' gehören. $\hat{\lambda} = (\hat{\lambda}_1, \hat{\lambda}_2, \dots, \hat{\lambda}_N) = \frac{y' \hat{f}}{(T-1)}$ ist die Matrix der zugehörigen Faktorladungen. Die Anzahl r der größten Eigenwerte wird ähnlich wie bisher durch eine maximale Zahl m festgesetzt. Ausgehend von dieser wird ein iteratives Verfahren gestartet.

Die idiosynkratischen Komponenten ergeben sich durch: $\hat{z}_{it} = y_{it} - \hat{\lambda}_i' \hat{f}_t$.

Um die Überdifferenzierung im zweiten Fall zu vermeiden, werden die geschätzten Werte angepasst: $\hat{e}_{it} = \sum_{s=2}^t \hat{z}_{is}$ und $\hat{F}_t = \sum_{s=2}^t \hat{f}_s$.

Der Test für die gemeinsamen Faktoren:

Die folgenden Ausführungen beziehen sich auf die Teststatistiken mit Konstante. Wenn nur ein gemeinsamer Faktor ermittelt wurde, also $r = 1$, wird der sogenannte $ADF_{\hat{F}}$ -Test durchgeführt, um zu testen ob dieser gemeinsame Faktor nicht stationär ist:

$$\Delta \hat{F}_t = \alpha_{i0} + \delta_0 \hat{F}_{t-1} + \delta_1 \Delta \hat{F}_{t-1} + \dots + \delta_p \Delta \hat{F}_{t-p} + u_{it} \quad (5.36)$$

Dieser Test hat dieselbe Grenzverteilung wie der Dickey Fuller Test mit Konstante. Der kritische Wert zu einem Signifikanzniveau von 5% ist $-2,857$.

Wenn $r > 1$ ist, wird iterativ überprüft, ob die wahre Anzahl der gemeinsamen nicht stationären Faktoren $r_1 = r$ ist. Dazu wird zunächst \hat{F}_t Mittelwert bereinigt, sei \hat{F}_t^c der Mittelwert bereinigte Vektor.

Dann wird mit $m = r$ gestartet und mittels der Methode der Hauptkomponenten die m größten Eigenwerte von $T^{-2} \sum_{t=2}^T \hat{F}_t^c \hat{F}_t^{c'}$ bestimmt. Seien $\hat{\beta}_\perp$ die zugehörigen m größten Eigenvektoren, und sei $\hat{Y}_t^c = \hat{\beta}_\perp' \hat{F}_t^c$.

Für die weitere Vorgehensweise gibt es zwei verschiedene Ansätze. Beim ersten werden die Faktoren unter der Annahme, dass sie eine endliche VAR-Repräsentation haben gefiltert und beim zweiten werden die Faktoren durch Schätzung der relevanten Störvariablen in Bezug auf Querschnittskorrelation korrigiert. Es handelt sich bei beiden um abgeänderte Versionen von Q_f und Q_c , welche von Stock und Watson (1988) entwickelt wurden.

Die beiden Varianten im Detail:

1. Sei $K(j) = 1 - \frac{j}{J+1}$ für $j = 0, \dots, J$, dann wird die $MQ_c(m)$ -Statistik, um Nullhypothese $r_1 = m$ zu testen, durch:

$$MQ_c(m) = T[\hat{v}_c(m) - 1] \quad (5.37)$$

gebildet, wobei $\hat{v}_c(m)$ der kleinste Eigenwert von:

$$\Phi_c(m) = 0,5 \left[\sum_{t=2}^T (\hat{Y}_t^c \hat{Y}_{t-1}^{c'} + \hat{Y}_{t-1}^c \hat{Y}_t^{c'}) - T(\hat{\Sigma}_1^c + \hat{\Sigma}_1^{c'}) \right] \left(\sum_{t=2}^T \hat{Y}_{t-1}^c \hat{Y}_{t-1}^{c'} \right)^{-1} \quad (5.38)$$

ist. $\widehat{\Sigma}_1^c = \sum_{j=1}^J K(j)T^{-1} \sum_{t=2}^T \widehat{\xi}_{t-j}^c \widehat{\xi}_t^{c'}$ ist die Varianz-Kovarianzmatrix der Residuen $\widehat{\xi}_t^{c'}$ einer VAR-Schätzung erster Ordnung von \widehat{Y}_t^c .

2. Sei p fix und nicht abhängig von T oder N , die $MQ_f(m)$ -Statistik, um dieselbe Nullhypothese zu testen, wird durch:

$$MQ_f(m) = T[\widehat{V}_f(m) - 1] \quad (5.39)$$

gebildet und $\widehat{V}_f(m)$ ist der kleinste Eigenwert von:

$$\Phi_f(m) = 0,5 \left[\sum_{t=2}^T (\widehat{y}_t^c \widehat{y}_{t-1}^{c'} + \widehat{y}_{t-1}^c \widehat{y}_t^{c'}) \right] \left(\sum_{t=2}^T \widehat{y}_{t-1}^c \widehat{y}_{t-1}^{c'} \right)^{-1}, \quad (5.40)$$

wobei $\widehat{y}_t^c = \widehat{\Pi}(L)\widehat{Y}_t^c$. $\widehat{\Pi}(L) = I_m - \widehat{\Pi}_1 L - \dots - \widehat{\Pi}_p L^p$ ist der Lag-Operator von einer VAR-Schätzung der Ordnung p von \widehat{Y}_t^c .

Wird die Nullhypothese $r_1 = m$ verworfen, wird $r_1 = m - 1$ gesetzt und die Verfahren von neuem gestartet, sonst wird gestoppt und $r_1 = m$ gesetzt.

Die kritischen Werte müssen für beide Varianten simuliert werden. Im Artikel von Bai und Ng (2005) sind die kritischen Werte zu einem Signifikanzniveau von 1%, 5% und 10% für bis zu sechs gemeinsame Faktoren auf Seite 1136 tabelliert.

Die für das Starten der rekursiven Verfahren notwendige Zahl m kann gleich der mit den Informationskriterien ermittelten Anzahl gemeinsamer Faktoren gesetzt werden.

Für die Variante mit einer Konstante und einem linearen Trend werden Mittelwert bereinigte erste Differenzen verwendet. Dazu wird von den differenzierten Daten das differenzierte Gruppenmittel abgezogen. Im Anschluss wird auf die so transformierten Daten die Methode der Hauptkomponenten angewendet, um die Faktoren und Faktorenladungen zu bestimmen. Für $r = 1$ wird die $ADF_{\widehat{F}}$ -Statistik um eine Trendkomponente erweitert. Die Grenzverteilung ist dann dieselbe wie die Dickey Fuller Verteilung mit einer Konstante und einem linearen Trend. Der kritische Wert zu einem Signifikanzniveau von 5% ist $-3,406$. Anstatt der Mittelwertbildung für \widehat{F}_t im Fall von $r > 1$, wird eine Regression von \widehat{F}_t auf eine Konstante und einen linearen Trend durchgeführt. Die Residuen dieser Regression werden für das Bilden der beiden Teststatistiken $MQ_f(m)$ und $MQ_c(m)$ verwendet.

Der Test für die idiosynkratische Komponente:

Sei $ADF_{\hat{e}}(i)$ die t-Statistik der i-ten Querschnittseinheit um die Nullhypothese $d_{i0} = 0$ in der Regression:

$$\Delta \hat{e}_{it} = d_{i0} \hat{e}_{it-1} + d_{i1} \Delta \hat{e}_{it-1} + \dots + d_{ip_i} \Delta \hat{e}_{it-p_i} + u_{it} \quad (5.41)$$

zu testen.

Die gepoolte Teststatistik wird dann unter der Annahme, dass die e_{it} unabhängig über i verteilt sind, durch:

$$P_{\hat{e}} = \frac{-2 \sum_{i=1}^N \log p_{\hat{e}}(i) - 2N}{\sqrt{4N}} \quad (5.42)$$

gebildet, wobei $p_{\hat{e}}(i)$ der p-Wert der $ADF_{\hat{e}}(i)$ -Statistik für die i-te Querschnittseinheit ist.

Die Teststatistik ist asymptotisch standardnormalverteilt. Die Nullhypothese wird zu einem Signifikanzniveau von 5% verworfen, wenn der Wert der Teststatistik absolut größer als 1,96 ist.

5.3.4 Der Test von Pesaran (2007)

Bei Pesaran (2007) [66] handelt es sich um ein Modell mit nur einem gemeinsamen Faktor.

Er hat gezeigt, dass die erste Differenz und die verzögerten Variablen des Querschnittseinheitenmittels ausreichen, um asymptotisch die Effekte des gemeinsamen unbekanntes Faktors zu approximieren. Der große Vorteil dieses Tests ist, dass der gemeinsame Faktor und die Faktorladungen nicht exakt bestimmt werden müssen.

Im Detail wird der gemeinsame Faktor durch das Querschnittsmittel von x_{it} , nämlich $\bar{x}_t = \frac{1}{N} \sum_{j=1}^N x_{jt}$ und seine verzögerten Werte $\bar{x}_{t-1}, \bar{x}_{t-2}, \dots$ approximiert. Wenn u_{it} unkorreliert ist, genügt zur Approximation \bar{x}_t und \bar{x}_{t-1} . Der ADF Test für die i-te Einheit wird um diese Variablen erweitert. Der sogenannte „Cross-Sectionally Augmented DF (CADF)“, hat dann die Form:

$$\Delta x_{it} = \alpha_i + \rho_i x_{it-1} + c_i \bar{x}_{t-1} + d_i \Delta \bar{x}_t + u_{it}, \quad (5.43)$$

wobei $\Delta\bar{x}_t = \frac{1}{N} \sum_{j=1}^N \Delta x_{jt}$ ist.

Die Unit Root Hypothese wird dann basierend auf den individuellen t-Statistiken der OLS-Schätzung von ρ_i , benannt mit $t_i(N, T)$, getestet.

Das ursprüngliche Querschnittsmittel \bar{x}_0 wird vor Durchführung der Testprozedur abgezogen, um zu verhindern, dass die Grenzverteilung von $t_i(N, T)$ Einflüssen der Störvariablen unterliegt.

Da die individuellen Teststatistiken asymptotisch unabhängig sind, kann im Prinzip jede Unit Root Teststatistik der ersten Generation angewendet werden. Pesaran schlägt die Verwendung einer modifizierten Version der t_bar -Statistik vor:

$$CIPS = \frac{1}{N} \sum_{i=1}^N t_i(N, T). \quad (5.44)$$

Die asymptotische Verteilung der Teststatistik ist im Gegensatz zur t_bar Statistik nicht normalverteilt und muss simuliert werden. Die kritischen Werte finden sich in den Tabellen 2b und 2c auf den Seiten 280 und 281 für die Modelle mit einer Konstante und mit einer Konstante und einem linearen Trend.

Pesaran (2007) gibt eine beschränkte Version der CIPS-Statistik an, welche den übertriebenen Einfluss von extremen individuellen Teststatistiken, sogenannten Ausreißern, eindämmt:

$$t_i(N, T)^* = t_i(N, T) \quad \text{wenn} \quad -K_1 < t_i(N, T) < -K_2 \quad (5.45)$$

$$t_i(N, T)^* = -K_1 \quad \text{wenn} \quad t_i(N, T) \leq -K_1 \quad (5.46)$$

$$t_i(N, T)^* = K_2 \quad \text{wenn} \quad t_i(N, T) \geq K_2 \quad (5.47)$$

und

$$CIPS^* = \frac{1}{N} \sum_{i=1}^N t_i(N, T)^* \quad (5.48)$$

Die Werte von K_1 und K_2 sind für Modelle mit Konstante $K_1 = 6,19$ und $K_2 = 2,61$ und für Modelle mit Konstante und linearem Trend $K_1 = 6,42$ und $K_2 = 1,7$.

Die $CIPS^*$ -Statistik hat dieselbe asymptotische Verteilung wie die CIPS-Statistik. Für sehr kleine N und T unterscheiden sich die kritischen Werte der CIPS- und $CIPS^*$ -Statistik voneinander, die entsprechenden abgeänderten Werte der $CIPS^*$ -Statistik sind in Klammern in den Tabellen 2b und 2c angeführt.

Pesaran (2007) schlägt weiter die Bildung von Teststatistiken basierend auf der Kombination individueller p-Werte der CADF Regressionen vor und präsentiert Choib (2001) P_m - und Z-Test. Die asymptotischen Verteilungen dieser sind unter der Annahme der Querschnittsabhängigkeit nicht mehr normalverteilt und die entsprechenden kritischen Werte müssen sowie jene von CIPS simuliert werden.

5.3.5 Der Test von Choi (2002)

Chois (2002) [21] Test geht von einem Zwei-Fachen Fehler Komponenten Modell aus:

$$x_{it} = \alpha_i + \mu_i + f_t + v_{it} \quad (5.49)$$

$$v_{it} = \sum_{l=1}^{p_i} \varepsilon_{il} v_{it-l} + e_{it}, \quad (5.50)$$

wobei α_i wie bisher die deterministische Komponente kennzeichnet. μ_i ist der un beobachtbare individuelle Effekt, f_t der un beobachtbare Periodeneffekt und v_{it} die übrige zufällige Komponente, welche einem $AR(p_i)$ -Prozess folgt. Die Ordnung der verzögerten Variablen kann für jede Querschnittseinheit unterschiedlich sein.

Im Prinzip handelt es sich bei Choib (2002) Test um ein homogenes Faktoren Modell mit nur einem gemeinsamen Faktor. Das bedeutet, dass der gemeinsame Faktor für jede Querschnittseinheit i mit dem gleichen Gewicht, $\lambda_i = 1$ für alle i , beeinflusst wird.

Choi (2002) nimmt an, dass die Ordnung der verzögerten Variablen p_i bekannt ist. In der Praxis kann sie wie bei LLC durch sequentielles Testen bestimmt werden.

Getestet wird nun die Nullhypothese der Unit Root-Stationarität durch:

$$H_0 : \sum_{l=1}^{p_i} \varepsilon_{il} = 1 \quad i = 1, \dots, N \quad (5.51)$$

gegen die Alternativhypothese, dass zumindest für ein i gilt $\sum_{l=1}^{p_i} \varepsilon_{il} < 1$.

Um die Hypothese (5.51) zu testen, werden zunächst die Daten Mittelwert bereinigt. Dazu werden im Modell mit einer Konstante alle Fehlerkomponenten bis auf

v_{it} und das gemeinsame Mittel α_{i0} von x_{it} eliminiert. Choi (2002) schlägt dazu eine GLS-Schätzung von α_{i0} im Sinne von Elliot, Rothenberg und Stock (1996) vor, welche bessere Eigenschaften in endlichen Stichproben als eine OLS-Schätzung aufweist. Es wird angenommen, dass die größte Wurzel von v_{it} gleich $(1 + \frac{c}{T})$ für alle i ist. Um nun α_{i0} zu bestimmen, wird $(x_{i1}, x_{i2} - (1 + \frac{c}{T})x_{i1}, \dots, x_{iT} - (1 + \frac{c}{T})x_{iT-1})$ auf $(1, 1 - (1 + \frac{c}{T}), \dots, 1 - (1 + \frac{c}{T}))$ regressiert, wobei Elliott, Rothenberg und Stock (1996) [29] zufolge $c = -7$ gesetzt wird. Damit ergibt sich die Mittelwert bereinigte Zeitreihe:

$$z_{it} = x_{it} - \hat{\alpha}_{i0} - \frac{1}{N} \sum_{i=1}^N (y_{it} - \hat{\alpha}_{i0}), \quad (5.52)$$

wobei $\hat{\alpha}_{i0}$ der GLS-Schätzer für α_{i0} ist.

Als nächstes wird für jede bereinigte Querschnittseinheit ein individueller ADF Test (5.52), der sogenannte „Dickey Fuller GLS“ Test durchgeführt. Hat man alle individuellen p-Werte bestimmt, werden diese für die Gesamtteststatistik addiert. Es werden dieselben Teststatistiken wie für die Unit Root Tests der ersten Generation von Choi (2001) angegeben. Für die NAMEA Daten werden wieder der Z-Test (5.11) und der P_m -Test (5.10) durchgeführt. Beide konvergieren unter der Nullhypothese asymptotisch gegen eine Standardnormalverteilung.

Wird der Test um einen linearen Trend $\alpha_{i1}t$ erweitert, welcher als querschnittskorreliert und mit den anderen Fehlerkomponenten unkorreliert angenommen wird, ändert sich die Testprozedur folgendermaßen: Die $(x_{i1}, x_{i2} - (1 + \frac{c}{T})x_{i1}, \dots, x_{iT} - (1 + \frac{c}{T})x_{iT-1})$ werden dann nicht nur auf $(1, 1 - (1 + \frac{c}{T}), \dots, 1 - (1 + \frac{c}{T}))$ sondern auch auf $(1, 1 - \frac{c}{T}, \dots, 1 - (\frac{c(T-1)}{T}))$ regressiert, um α_{i0} und α_{i1} zu bestimmen. c wird $-13,5$ gesetzt.

Die Mittelwert bereinigte Reihe setzt sich dann aus:

$$z_{it} = x_{it} - \hat{\alpha}_{i0} - \hat{\alpha}_{i1}t - \frac{1}{N} \sum_{i=1}^N (x_{it} - \hat{\alpha}_{i0} - \hat{\alpha}_{i1}t) \quad (5.53)$$

zusammen.

Im Anschluss werden wieder individuelle ADF Tests durchgeführt und der p-Wert ermittelt, um die gemeinsame Teststatistik zu bestimmen.

5.3.6 Vergleich der Tests

Moon und Perron (2004), Phillips und Sul (2003) und Pesaran (2007) verwenden dieselbe dynamische Struktur, wobei die beiden letztgenannten ein Faktoren Modell mit einem gemeinsamen Faktor betrachten. Der Ansatz von Moon und Perron (2004) lässt mehrere gemeinsame Faktoren zu, dafür beinhalten die Teststatistiken keine deterministische Komponente. Bai und Ng (2004) präsentieren den allgemeinsten Faktoren Ansatz. Mit ihrem Ansatz können sowohl die idiosynkratischen Komponenten als auch die gemeinsamen Faktoren getrennt und voneinander unabhängig auf Stationarität untersucht werden. Moon und Perron (2004), Phillips und Sul (2003) und Pesaran (2007) untersuchen nur die idiosynkratische Komponente auf Nicht-Stationarität.

Ist die Nicht-Stationarität nur von einem gemeinsamen Faktor abhängig, kann diese nur mit dem Test von Bai und Ng (2004) untersucht werden.

Choi (2002) hingegen betrachtet ein Zwei-Faches Fehler Komponenten Modell.

Gutierrez (2006) führt Simulationen durch, um die Macht der Tests in endlichen Stichproben zu untersuchen. Seine Ergebnisse zeigen, dass prinzipiell die Macht der Tests steigt je mehr Querschnittseinheiten und Zeitperioden im Panel vorliegen. Die Tests t_a und t_b von Moon und Perron (2004) zeigen die größte Macht der Tests für alle N und T und verschiedene Spezifikationen ohne deterministische Komponente.

Das Modell von Choi (2002) ist überdimensioniert, wenn die einzelnen Querschnittseinheiten nicht gleich durch den gemeinsamen Faktor beeinflusst werden. Der Test von Phillips und Sul (2003) liefert sehr gute Ergebnisse, wenn nur ein gemeinsamer Faktor im Panel vorhanden ist, sonst ist der Test überdimensioniert. Die Simulationsergebnisse haben weiter gezeigt, dass in diesem Fall der G_{OLS}^{++} -Test größere Macht als der gepoolte Z-Test von Choi(2002) hat.

Laut den Simulationsergebnissen von Gengenbach, Palm und Urbain (2010) ist auch der CIPS-Test von Pesaran (2007) sehr gut geeignet, um die Nullhypothese der Unit Root-Stationarität zu testen, wenn die Querschnittsabhängigkeiten durch einen gemeinsamen Faktor verursacht werden. Die Macht des Tests wird durch einen zweiten gemeinsamen Faktor sehr stark beeinflusst.

Trifft für die Daten keine gruppenweise Korrelation zu, so sind die Tests von Moon und Perron (2004) und Bai und Ng (2004) überdimensioniert.

Der Test für den gemeinsamen Faktor von Bai und Ng (2004) ist bereits für kleine Werte von N und T ($N, T \geq 50$) durch eine hohe Macht des Tests gekennzeichnet, wenn die serielle Korrelation nicht zu stark ist. Gengenbach, Palm und Urbain (2010) zeigen hingegen, dass die Tests für mehrere gemeinsame Faktoren von Bai und Ng (2004) nicht im Stande sind starke stationäre serielle Korrelation von Nicht-Stationarität in den gemeinsamen Faktoren zu unterscheiden. Prinzipiell liefert der MQ_c -Test bessere Ergebnisse als der MQ_f -Test.

Diese präsentierten Simulationsergebnisse wurden unter der Annahme, dass die Anzahl der gemeinsamen Faktoren bekannt ist, erzielt. Das Bestimmen der Anzahl der gemeinsamen Faktoren kann die Ergebnisse des Tests von Bai und Ng (2004) und Moon und Perron (2004) beeinflussen. Für $N > 20$ können die präsentierten Informationskriterien die Anzahl der gemeinsamen Faktoren exakt bestimmen. Gengenbach, Palm und Urbain (2010) argumentieren, dass die Informationskriterien in Simulationen sehr gut funktionieren, die Anwendung in der Praxis jedoch sehr schwierig ist. Es wurde beobachtet, dass sie in der Regel die maximal erlaubte Anzahl an gemeinsamen Faktoren wählen. Sie zeigen, dass es geringere Auswirkungen hat zu viele gemeinsame Faktoren in den Testprozeduren zu inkludieren als zu wenige. Im zweiten Fall kommt es zu schweren Verzerrungen der Teststatistiken.

Wird ein linearer Trend im Modell mitgeschätzt, verlieren die Tests wegen der Komplexität der fixen Effekte stark an Macht. Dieses Ergebnis ist nicht unbekannt, unter anderen weisen Moon, Phillips und Perron (2007) auf dieses Problem hin.

5.3.7 Die NAMEA Testergebnisse

Der erste Schritt in der Analyse der Nicht-Stationaritäten mit dem Faktoren Ansatz ist die Bestimmung der Anzahl der gemeinsamen Faktoren mit den Informationskriterien. Diese werden nach dem Ansatz von Bai und Ng (2004) auf die Differenzen der Variablen angewendet und im Anschluss die so ermittelten gemeinsamen Faktoren mit dem Test für die gemeinsamen Faktoren von Bai und Ng (2004) auf die Existenz einer Einheitswurzel untersucht. Zusätzlich wird die Anzahl der nicht stationären gemeinsamen Faktoren durch die Informationskriterien aus Bai (2004) angewendet auf die Niveaus der Variablen bestimmt. Die Testergebnisse sind in der Tabelle 5.3 tabelliert.

Tabelle 5.3: Die Testergebnisse für die gemeinsamen Faktoren

Variable	Anzahl der gemeinsamen nicht stationären Faktoren		$ADF_{\hat{F}}$ mit Konstante und linearem Trend	
		mit Konstante		
$\log(\frac{BW}{EW})$	1	-2,90418		-255,57
$\log(\frac{BW}{EW})^2$	1	-2,84523		-67,8854
$\log(\frac{BW}{EW})^3$	1	-2,79596		-25,5682
$\log(\frac{Prod}{EW})$	1	-1,6546		-1,52812
$\log(\frac{Prod}{EW})^2$	1	-1,62752		-1,56408
$\log(\frac{Prod}{EW})^3$	1	-1,6044		-1,5728
$\log(\frac{CO}{EW})$	1	-3,46701		-3,23083
$\log(\frac{CO_2}{EW})$	1	-2,25444		-0,993456
$\log(\frac{CH_4}{EW})$	1	-1,58151		0,331406
$\log(\frac{SO_2}{EW})$	1	-0,512044		-1,5957
$\log(\frac{NO_x}{EW})$	1	4,74473		-1,85723

Die Informationskriterien für die Anzahl der nicht stationären gemeinsamen Faktoren angewendet auf die Niveaus der Variablen ermitteln einheitlich einen gemeinsamen nicht stationären Faktor. In diesem Zusammenhang ist zu beachten, dass laut den Informationskriterien immer zumindest ein gemeinsamer nicht stationärer Faktor existiert.

Die Informationskriterien für die Anzahl der gemeinsamen Faktoren angewendet auf die Differenzen der Variablen sowie auf die Residuen einer gepoolten Regression ermitteln einheitlich einen gemeinsamen Faktor. Die entsprechenden Ergebnisse sind nicht tabelliert.

Da für jede Variable nur ein gemeinsamer Faktor bestimmt wird, wird im Anschluss dieser gemeinsame Faktor für jede Variable mit dem $ADF_{\hat{F}}$ -Test auf Stationarität untersucht. Der kritische Wert für den $ADF_{\hat{F}}$ -Test zu einem Signifikanzniveau von 5% lautet für das Modell mit Konstante $-2,86$ und für das Modell mit Konstante und linearem Trend $-3,406$.

Für die Bruttowertschöpfung pro Erwerbstätigen wird die Nullhypothese, dass der gemeinsame Faktor Unit Root-stationär ist, in beiden Modellvarianten verworfen. Für das Quadrat und die dritte Potenz der Bruttowertschöpfung pro Erwerbstätigen

wird die Nullhypothese für das Modell mit Konstante und linearem Trend verworfen und jene für das Modell mit Konstante angenommen, wobei die Testentscheidungen der zweiten Modellvariante an der Grenze liegen. Für Kohlenmonoxid und Stickstoff werden die Nullhypothesen in der Variante mit Konstante verworfen. Für die anderen Variablen muss die Nullhypothese, dass der gemeinsame Faktor eine Einheitswurzel hat, in beiden Modellen angenommen werden.

Im zweiten Schritt werden die idiosynkratischen Komponenten auf Stationarität untersucht. Die Analyse ist weiter entwickelt als die Analyse der gemeinsamen Faktoren. Sie gliedert sich in zwei Schritte, zunächst werden die idiosynkratischen Komponenten geschätzt und danach wird ein Panel Unit Root Test durchgeführt. Die Schätzung der idiosynkratischen Komponenten kann als äquivalent zur Schätzung der deterministischen Komponenten betrachtet werden.

Im Folgenden werden die Tests für die idiosynkratische Komponente aus den Ansätzen von Pesaran (2007) (CIPS), Choi(2002) (Z und P_m) und Bai und Ng (2004) ($P_{\hat{c}}$) durchgeführt. Die Testergebnisse befinden sich in den Tabellen 5.4 für das Modell mit Konstante und in 5.5 für das Modell mit Konstante und linearem Trend.

Die kritischen Werte betragen zu einem Signifikanzniveau von 5% für die CIPS-Statistik im Modell mit Konstante $-2,28$ und im Modell mit Konstante und linearem Trend $-2,83$ mit $N = 15$ und $T = 15$. Für den P_m -Test der zweiten Generation ist der kritische Wert $1,645$ und für den Z-Test der zweiten Generation $-1,645$, sowie $1,96$ für die $P_{\hat{c}}$ -Statistik.

Bei beiden Modellvarianten müssen für sämtliche Variablen drei der vier Teststatistiken der Existenz einer Einheitswurzel in den idiosynkratischen Komponenten abgelehnt werden. Die CIPS-Statistik führt als einzige in allen Fällen zur Annahme der Nullhypothese.

Aus den Testergebnissen lässt sich schließen, dass die idiosynkratischen Komponenten der einzelnen Variablen stationär sind. Die gemeinsamen Faktoren hingegen sind größtenteils nicht stationär. Da es für die Analyse der gemeinsamen Faktoren nur einen Test gibt, ist kein Vergleich mit anderen Ergebnissen möglich. Die Ergebnisse der Tests sind kritisch zu betrachten, da laut Gengenbach, Palm und Urbain (2010) die Anzahl der gemeinsamen Faktoren erst in Panels mit einer Anzahl von mehr als 20 Querschnittseinheiten korrekt ermittelt werden kann.

Tabelle 5.4: Die Testergebnisse für die idiosynkratische Komponente im Modell mit Konstante

Variable	CIPS ($CIPS^*$)	$Z^{2.Gen}$	$P_m^{2.Gen}$	P_e
$\log(\frac{BW}{EW})$	-0,77654002(-0,84507082)	-7,5439272	12,776152	3,39963
$\log(\frac{BW}{EW})^2$	-0,76120952(-0,83324617)	-7,4296411	12,375960	3,38123
$\log(\frac{BW}{EW})^3$	-0,74838745(-0,82294853)	-7,2087418	11,922885	3,3826
$\log(\frac{Prod}{EW})$	-0,55646586	-8,0856352	14,268516	4,25626
$\log(\frac{Prod}{EW})^2$	-0,84507948	-6,5805670	11,331976	5,09406
$\log(\frac{Prod}{EW})^3$	-1,1040941	-6,6608874	11,292253	5,12401
$\log(\frac{CO}{EW})$	-0,16454715	-2,3564034	2,7331028	7,14765
$\log(\frac{CO2}{EW})$	-0,253189	-4,0641526	4,5691833	3,79657
$\log(\frac{CH4}{EW})$	-0,16296129	-2,6146340	2,6145614	2,77969
$\log(\frac{SO2}{EW})$	-0,93617135	-5,4876878	13,661825	1,90596
$\log(\frac{NOx}{EW})$	-0,25681313	-4,1681307	6,2186071	4,51454

Tabelle 5.5: Die Testergebnisse für die idiosynkratische Komponente im Modell mit Konstante und linearem Trend

Variable	CIPS ($CIPS^*$)	$Z^{2.Gen}$	$P_m^{2.Gen}$	P_e
$\log(\frac{BW}{EW})$	-1,1060801(-1,1599365)	-13,200024	29,629610	8,38154
$\log(\frac{BW}{EW})^2$	-1,0557839(-1,1124782)	-13,116305	29,180329	8,41739
$\log(\frac{BW}{EW})^3$	-1,0091391(-1,0677863)	-13,030093	28,723727	8,12555
$\log(\frac{Prod}{EW})$	-0,46109368	-11,701780	23,155254	9,82625
$\log(\frac{Prod}{EW})^2$	-0,76704579	-11,698042	23,162816	9,69737
$\log(\frac{Prod}{EW})^3$	-1,0527137	-11,405939	22,160667	9,65603
$\log(\frac{CO}{EW})$	-0,20449583	-10,746631	20,162634	5,27098
$\log(\frac{CO2}{EW})$	-0,28593072	-10,853339	19,672120	7,28189
$\log(\frac{CH4}{EW})$	-0,13375779	-8,8420721	13,758189	5,97158
$\log(\frac{SO2}{EW})$	-0,91993925	-11,141053	19,982001	8,79339
$\log(\frac{NOx}{EW})$	-0,19421665	-11,435815	22,223701	8,12966

5.4 Zweite Generation der Einheitswurzeltests - Weitere Ansätze zur Behandlung der Querschnittsabhängigkeiten

Die folgenden Ansätze der Einheitswurzeltests der zweiten Generation sind allgemeiner als der Faktoren Ansatz. Sie stellen im Allgemeinen keine oder nur wenige Restriktionen an die Kovarianzmatrix der Residuen.

5.4.1 Der Test von Chang (2002)

Chang (2002) [17] entwickelt in ihrem Paper einen nicht-linearen Instrumentenvariablen (IV) Unit Root Test.

Die konstruierten individuellen Teststatistiken sind asymptotisch unabhängig, auch wenn die Querschnittseinheiten Abhängigkeiten aufweisen. Die verwendeten Instrumente und deren Eigenschaften sind für die Unabhängigkeit verantwortlich.

Präzise wird der Test wie folgend konstruiert:

Ausgangspunkt ist das Modell (5.1) mit $\alpha_{it} = 0$, wobei der Störterm u_{it} ein invertierbarer $AR(p_i)$ Prozess ist: $\lambda^i(L)u_{it} = \varepsilon_{it}$ mit L dem Lag Operator und $\lambda^i(z) = 1 - \sum_{j=1}^{p_i} \beta_{ij}z^j$. Die Heterogenität der Querschnittseinheiten wird durch unterschiedliche ρ_i und p_i modelliert. Außerdem kann die Anzahl der Zeitperioden der einzelnen Querschnittseinheiten verschieden sein. Die gruppenweise Abhängigkeit wird durch die ε_{it} beschrieben, welche u_{it} generieren.

Mit Hilfe der Darstellung des Störterms kann das Modell folgendermaßen umgeschrieben werden:

$$x_{it} = \rho_i x_{it-1} + \sum_{j=1}^{p_i} \beta_{ij} u_{it-j} + \varepsilon_{it}. \quad (5.54)$$

Da unter der Nullhypothese $\Delta x_{it} = u_{it}$ gilt, folgt:

$$x_{it} = \rho_i x_{it-1} + \sum_{j=1}^{p_i} \beta_{ij} \Delta x_{it-j} + \varepsilon_{it}. \quad (5.55)$$

Um die gruppenweise Abhängigkeit zu behandeln, werden Instrumente konstruiert. Für das verzögerte Level x_{it-1} wird eine nicht-lineare Funktion $F(\cdot)$ konstruiert. Für die verzögerten Differenzen $(\Delta x_{it-1}, \dots, \Delta x_{it-p_i})$ dienen die Variablen selbst als

Instrumente. Die Funktion der Instrumente wird von Chang als „Instrument Generating Function (IGF)“ bezeichnet. Für die IGF sollten folgende Eigenschaften gelten: Sie muss integrierbar sein und $\int_{-\infty}^{\infty} yF(y)dy \neq 0$ erfüllen. Das bedeutet, dass die verwendeten Instrumente und der Regressor korreliert sein müssen, da sonst die IV-Schätzung nicht konsistent durchgeführt werden kann. Beispiele für das Instrument von x_{it-1} sind Funktionen des Typs $ye^{-|y|}$ und Indikatorfunktionen, die auf einem kompakten Intervall definiert sind: $F(y) = I\{|y| \leq K\}$ mit K einem Abbruchparameter.

Der IV-Schätzer $\hat{\rho}_i$ wird nun durch eine AR Regression der durch Verwendung der Instrumente transformierten Gleichung (5.55) geschätzt:

$$\hat{\rho}_i - 1 = \frac{\sum_{t=2}^T F(x_{it-1})\varepsilon_{it} - \sum_{t=2}^T F(x_{it-1})z'_{it}(\sum_{t=2}^T z_{it}z'_{it})^{-1}\sum_{t=2}^T z_{it}\varepsilon_{it}}{\sum_{t=2}^T F(x_{it-1})x_{it-1} - \sum_{t=2}^T F(x_{it-1})z'_{it}(\sum_{t=2}^T z_{it}z'_{it})^{-1}\sum_{t=2}^T z_{it}x_{it-1}} \quad (5.56)$$

mit $z_{it} = (\Delta x_{it-1}, \dots, \Delta x_{it-p_i})$ und ε_{it} den Schätzern der Residuen der OLS Regression von (5.55).

Die Teststatistik für die i -te Gruppe wird dann durch $t_{IV_i} = \frac{\hat{\rho}_i - 1}{s(\hat{\rho}_i)}$ definiert, wobei $s(\hat{\rho}_i)$ die Standardabweichung des IV-Schätzers für die i -te Querschnittseinheit bezeichnet.

Für die asymptotische Standardnormalverteilung der Gesamtteststatistik spielt die Orthogonalität der Querschnittseinheiten eine zentrale Rolle. Dazu müssen die Kovarianzen der einzelnen Querschnittseinheiten asymptotisch unkorreliert sein. Diese Eigenschaft wird einerseits durch die verwendeten nicht-linearen Instrumente für die korrelierten Variablen x_{it-1} und x_{jt-1} , sowie eine Einschränkung an die unterschiedliche Anzahl der Zeitperioden der einzelnen Querschnittseinheiten, T_i , erreicht. Wenn die T_i s asymptotisch gegen unendlich laufen, muss für T_{min} und T_{max} die minimale und maximale Anzahl der Zeitperioden gelten: $T_{min} \rightarrow \infty$ und $T_{max}^{1/4} \ln\left(\frac{T_{max}}{T_{min}^{3/4}}\right) \rightarrow 0$.

Dann kann die Teststatistik mit asymptotischer Standardnormalverteilung, wie im Fall von IPS als arithmetisches Mittel der einzelnen t_{IV_i} -Statistiken konstruiert werden:

$$t_{IV} = \frac{1}{\sqrt{N}} \sum_{i=1}^N t_{IV_i}. \quad (5.57)$$

Die Nullhypothese wird abgelehnt, wenn zumindest eine Querschnittseinheit sta-

tionär ist.

Für die Modelle mit Konstante und Trend werden die Zeitreihen vor Durchführen der Instrumentenvariablen Schätzung Mittelwert bzw. Trend bereinigt. Anders als bisher wird dazu ein „adaptives“ Verfahren angewendet. Shin und So (1999) haben dieses Verfahren entwickelt um positiv korrelierte AR-Prozesse Mittelwert zu bereinigen. Es reduziert die Verzerrung der Schätzung und im Fall des IV-Schätzers von Chang (2002) garantiert es, dass die an die Instrumente geforderten Eigenschaften nicht verletzt werden.

Im Modell mit Konstante wird das übliche arithmetische Mittel zur Schätzung des Mittelwertes durch die Partialsumme der Daten bis zum Wert $t - 1$ ersetzt und von x_{it} und x_{it-1} abgezogen. Für die verzögerten Differenzen ist keine Anpassung nötig, da die Differenzenbildung bereits den Mittelwert bereinigt.

Für die Trend Bereinigung werden sowohl α_{t0} und α_{t1} durch ein „adaptives“ Verfahren geschätzt. Für die genaue Durchführung wird auf den Artikel von Chang(2002) verwiesen.

Chang (2002) führt in ihrem Paper Simulationstests im Vergleich mit dem Test von IPS durch. Sie kann zeigen, dass ihr IV-Test in allen Ausführungen bessere Ergebnisse in Bezug auf die Macht der Tests liefert. Vor allem für kleine Werte von N und T sind die Unterschiede bedeutend und der IV-Test ist dem t_bar -Test überlegen. Je stärker die Gruppen untereinander korreliert sind, desto stärker sind die Größenverzerrungen im Test von IPS.

Im und Pesaran (2003) haben gezeigt, dass der Test von Chang nur funktioniert wenn $N \frac{\ln T}{\sqrt{T}} \rightarrow 0$ gilt. Das bedeutet, dass N im Vergleich zu T sehr klein sein muss.

5.4.2 Der Test von Shin und Kang (2006)

Shin und Kang (2006) [73] verwenden für das Durchführen des Panel Unit Root Tests sogenannte „Huber Instrumente“. Im Gegensatz zu Chang (2002) handelt es sich bei den „Huber Instrumenten“ nicht um integrierbare Funktionen, sondern um eine Signumfunktion mit den folgenden Eigenschaften:

Die Matrix der „Huber Instrumente“ $H_t = \text{diag}(h_{1t}, \dots, h_{Nt})$ wird durch

$$h_{it} = h_m(\hat{\sigma}_{ii}^{-1/2} x_{it-1}) \quad (5.58)$$

konstruiert, wobei $\hat{\sigma}_{ii}$ ein Schätzer für das (i,i)-Element der Kovarianzmatrix der Fehler und $h_m(x)$ die Signumfunktion mit:

$$h_m(x) = \begin{cases} 1 & x > m \end{cases} \quad (5.59)$$

$$h_m(x) = \frac{x}{m} \quad |x| \leq m \quad (5.60)$$

$$h_m(x) = \begin{cases} -1 & x < -m \end{cases} \quad (5.61)$$

ist.

Die Kovarianzmatrix der Fehler wird durch $S_u = \frac{1}{T-p} \sum_{t=p+1}^T \hat{u}_t \hat{u}_t'$ geschätzt, wobei $\hat{u}_{it} = x_{it} - \hat{\rho} x_{it-1}$ der Schätzer für die OLS-Residuen unter der Nullhypothese ist und u_t der N-dimensionale Vektor (u_{1t}, \dots, u_{Nt}) .

Der IV-Schätzer $\hat{\rho}$ wird durch gebildet:

$$\hat{\rho}_{IV} = \left(\sum_{t=2}^T H_t' X_t^* \right)^{-1} \sum_{t=2}^T H_t' x_t^*, \quad (5.62)$$

wobei $X_t = \text{diag}(x_{1t}, \dots, x_{Nt})$ ist und X_t^* das mit Γ_u vormultiplizierte X_t . Γ_u ist die Zerlegung von S_u mit $S_u^{-1} = \Gamma_u \Gamma_u'$.

Die Teststatistik um die Nullhypothese, dass ein Random Walk vorliegt, zu testen, lautet:

$$W_{IV} = \hat{\rho}_{IV}' V_{IV}^{-1} \hat{\rho}_{IV}, \quad (5.63)$$

wobei V_{IV} die Varianz von $\hat{\rho}_{IV}$ ist.

Die konstruierte Teststatistik ist unter der Nullhypothese χ^2 -verteilt mit N Freiheitsgraden.

Shin und Kang (2006) schlagen weiter das Verwenden von Teststatistiken basierend auf dem individuellen p-Wert im Sinne von Choi (2001), sowie eine Teststatistik basierend auf der Methode von IPS vor.

Die Teststatistik von IPS für die transformierten Daten ist:

$$t_bar_{IV} = \frac{1}{\sqrt{N}} \sum_{i=1}^N t_bar_{IVi}. \quad (5.64)$$

Die individuellen Statistiken werden durch $t_bar_{IVi} = \frac{\sum_{t=p+1}^T h_{it} \hat{u}_{it}^*}{\sum_{t=p+1}^T h_{it}^2}$ gebildet, wobei

\hat{u}_{it}^* die mit Γ_u vormultiplizierten Schätzer der Residuen sind. Sie ist asymptotisch normalverteilt.

Da für das Bilden der Teststatistiken die Inverse der Kovarianzmatrix der Fehler benötigt wird, muss $N > T$ sein, damit die Kovarianzmatrix nicht singulär ist.

Ein Vorteil der „Huber Methode“, wie aus $h_m(x)$ ersichtlich, ist, dass bei starker Korrelation die Regressoren auf ihr Vorzeichen skaliert werden. Dadurch wird die Schätzung robuster. Auch Huber (1981) verwendete diese Methode um große Schätzfehler bei AR Regressionen auf ihr Vorzeichen zu reduzieren, woher der Name „Huber Instrumente“ stammt. Bei Chang (2002) gibt es keine Behandlung für diese Extremfälle.

Wie bei Chang(2002) wird die Konstante durch ein „adaptives“ Verfahren geschätzt und von den Daten abgezogen. Für den linearen Trend wird eine Regression von y_{is} auf $(1, s)$, wobei $s = 1, \dots, t$, durchgeführt und so rekursiv α_{i0} und α_{i1} durch die Koeffizienten von $(1, s)$ bestimmt. Diese Methode unterscheidet sich von jener von Chang (2002).

Die rekursive Bestimmung der Konstante und des linearen Trends garantiert außerdem, dass $h_m(\cdot)$ von u_{it} abhängt.

5.4.3 Der Test von Lopez (2009)

Lopez(2009) [50] verbindet den ADF-SUR Test von Papell und Theodoridis (2001) und das DF-GLS Prinzips von Elliott, Rothenberg und Stock (1996), um einen GLS-Schätzer zu definieren, mit welchen auch unter Querschnittsabhängigkeiten effiziente Schätzungen durchführbar sind.

Die Testprozedur gliedert sich in drei Schritte:

Zuerst werden die Daten GLS-transformiert, dazu wird ähnlich wie beim Test von Choi (2002) vorgegangen, jedoch wird $(1 + \frac{c}{T})$ durch $(1 + \frac{c}{N^{\kappa T}})$ ersetzt. κ wird im Modell mit Konstante gleich $\frac{1}{2}$ gesetzt und im Modell mit Konstante und linearem Trend gleich $\frac{1}{4}$, diese Werte beruhen auf einer Berechnung von Moon, Perron und Phillips(2007).

Im nächsten Schritt wird p_i , die maximale verzögerte Ordnung der Variablen, für jede Querschnitteinheit bestimmt. Lopez (2009) verwendet für die Bestimmung das MAIC Kriterium, welches von Ng und Perron (2001) entwickelt wurde und

laut Lopez die beste Kombination von Größe und Signifikanz in endlichen Stichproben liefert.

Zum Schluss wird die Kovarianzmatrix der Residuen Σ geschätzt. Diese wird benötigt um den Test mit der SUR Methode durchzuführen, welche die Werte von ρ identisch für alle Querschniteinheiten setzt und die zuvor bestimmten p_i benötigt. Dazu wird in

$$z_{it} = \rho z_{it-1} + \sum_{l=1}^{p_i} \rho_l \Delta y_{it-l} + u_{it} \quad (5.65)$$

ρ geschätzt, wobei z_{it} die GLS-transformierten Daten beschreibt. Im Anschluss werden die Schätzung von $\hat{\rho}$ und seine Standardabweichung $STD(\hat{\rho})$ verwendet, um die t-Statistik zu berechnen:

$$t^{GLS} = \frac{(\hat{\rho} - 1)}{STD(\hat{\rho})}. \quad (5.66)$$

Da für das Bilden der Teststatistik die SUR Methode herangezogen wird, kann der Test nicht durchgeführt werden, wenn N kleiner als T ist. Für die NAMEA Daten ist diese Annahme natürlich nicht erfüllt.

5.4.4 Der Test von Jönsson (2005)

Jönsson (2005) [44] entwickelt eine effiziente Teststatistik unter Querschnittskorrelation, welche sich besonders für kleinere Paneldatensätze eignet und für N kleiner als T durchführbar ist. Die Teststatistik beruht auf korrigierten Standardfehlern („Panel Corrected Standard Errors (PCSE)“) des Paneldatensatzes im Sinne von Beck und Katz (1995).

Für das Bilden der Teststatistik wird zunächst der OLS-Schleifen-Schätzer benötigt: Sei β^{PCSE} der Schätzer, welcher durch $\beta^{PCSE} = (X_{-1}^{*'} X_{-1}^*)^{-1} X_{-1}^{*'} X^*$ bestimmt wird, wobei X^* den NT -dimensionalen Vektor der Daten und X_{-1}^* den $N(T-1)$ -dimensionalen Vektor, der um eine Einheit verzögerten Daten, bezeichnet. Im Anschluss werden die Residuen gebildet: $u_{it} = X^* - X_{-1}^* \beta^{PCSE}$, um die Kovarianzmatrix der Residuen zu bestimmen. Die Kovarianzmatrix wird durch $\Omega = \Sigma \otimes E_{T-1}$ gebildet, wobei \otimes das Kronecker Produkt bezeichnet und das ij -te Element von Σ durch $\Sigma_{ij} = \frac{u_i u_j}{T-1}$ definiert ist.

Die Teststatistik des PCSE-Schätzers wird dann durch

$$t^{PCSE} = \frac{\beta^{PCSE} - 1}{s(\beta^{PCSE})} \quad (5.67)$$

definiert, wobei $s(\beta^{PCSE})$ die Standardabweichung des OLS-Schleifen-Schätzers bezeichnet, welche durch $s(\beta^{PCSE}) = ((X_{-1}'X_{-1})^{-1}X_{-1}'\Omega X_{-1}(X_{-1}'X_{-1})^{-1})^{1/2}$ gebildet wird.

Die Grenzverteilung der PCSE-Statistik ist abhängig von den Störtermen. Jönsson (2005) simuliert die kritischen Werte des PCSE-Tests und gibt die „Response Surface“ Koeffizienten an, aus welchen für verschiedene N und T die kritischen Werte zu unterschiedlichen Signifikanzniveaus bestimmt werden können.

Für die Modelle mit einer Konstante und mit einer Konstante und einem linearen Trend schlägt Jönsson (2005) die Methode von Elliot, Rothenberg und Stock (1996) zur Bereinigung der Daten vor, wobei darauf hingewiesen wird, dass die Schätzung mit einer Trendkomponente mit Vorsicht durchgeführt werden soll.

Jönsson (2005) vergleicht seinen Test in Monte Carlo Simulationen mit dem Test von Levin, Lin und Chu (2002), um die Macht der Tests unter Unabhängigkeit der einzelnen Zeitreihen zu untersuchen. Seine Ergebnisse zeigen, dass der PCSE-Test geringere Macht als der Test von LLC hat, wenn keine Querschnittskorrelation vorliegt. Diese Verringerung der Macht des Tests kann als Konsequenz der Anpassung für die Querschnittsabhängigkeiten gesehen werden. Der Test von Jönsson (2005) eliminiert die gruppenweisen Abhängigkeiten nicht, sondern verringert nur deren Einfluss.

5.4.5 Der Test von Breitung und Das (2005)

Wie von Chang (2004) argumentiert sind die asymptotischen Verteilungen der Tests beeinflusst durch die Parameter, welche die kurzfristigen Dynamiken der Zeitreihen beeinflussen. Breitung und Das (2005) [14] entwickeln das sogenannte „Pre-Whitening“-Verfahren, um diese kurzfristigen Abhängigkeiten zwischen den einzelnen Querschnittseinheiten behandeln zu können. Sie betrachten zwei unterschiedliche Teststatistiken. Die erste basiert auf einer robusten Version der Dickey Fuller t-Statistik und die zweite auf einer GLS-t-Statistik.

Die Daten werden durch einen AR(p)-Prozess modelliert. Den Ausgangspunkt für das Modell bildet die ADF Darstellung in differenzierter Form (5.2). Die Ordnung p_i der autoregressiven Parameter kann für jede Querschnittseinheit unterschiedlich sein.

Die von Levin, Lin und Chu (2003) vorgeschlagene Regression von Δx_{it} und x_{it-1} auf $(\Delta x_{it-1}, \dots, \Delta x_{it-p})$ ist Breitung und Das (2005) folgend nicht im Stande die Effekte der kurzfristigen Dynamiken auf die asymptotische Verteilung der Teststatistiken unter der Nullhypothese zu eliminieren. Sie schlagen die Verwendung des „Pre-Whitening“-Verfahrens vor. Bei diesem werden die autoregressiven Parameter $\gamma_1, \dots, \gamma_{p_i}$ direkt im Modell (5.3) geschätzt und von x_{it} abgezogen. Das funktioniert nur unter der Voraussetzung, dass die Nullhypothese zutrifft. In diesem Fall gilt, dass x_{it} ein Random Walk und Δx_{it} weißes Rauschen ist.

Im Anschluss wird mit der mit dem „Pre-Whitening“-Verfahren behandelten Zeitreihe, x_{it}^* , die robuste DF-t-Statistik gebildet:

$$t_{rob} = \frac{\sum_{t=1}^T x_{t-1}^{*'} \Delta x_t^*}{\sum_{t=1}^T x_{t-1}^{*'} \widehat{\Omega} x_{t-1}^*}. \quad (5.68)$$

Dabei ist x_{t-1}^* der N -dimensionale Vektor $(x_{1t-1}^*, \dots, x_{Nt-1}^*)$ und $\Delta x_t^* = (\Delta x_{1t}^*, \dots, \Delta x_{Nt}^*)$. $\widehat{\Omega}$ ist ein Schätzer für die Kovarianz, welcher durch $\widehat{\Omega} = \frac{1}{T} \sum_{t=1}^T (\Delta x_t^* - \widehat{\phi} x_{t-1}^*) (\Delta x_t^* - \widehat{\phi} x_{t-1}^*)'$ gebildet wird.

Die Verteilung der t_{rob} -Statistik ist asymptotisch standardnormalverteilt, wobei es für kleinere Stichproben zu Abweichungen kommt. Eine Tabelle der kritischen Werte für endliche Stichproben findet sich auf Seite 420 im Artikel von Breitung und Das (2005). Trifft die Gegenhypothese zu, sind alle Zeitreihen stationär.

Weiter geben Breitung und Das (2005) einen GLS-Schätzer an:

$$t_{GLS} = \frac{\sum_{t=1}^T x_{t-1}^{*'} \widehat{\Omega}^{-1} \Delta x_t^*}{\sum_{t=1}^T x_{t-1}^{*'} \widehat{\Omega}^{-1} x_{t-1}^*}. \quad (5.69)$$

Der GLS-Schätzer kann nur für $T > N$ gebildet werden, da sonst der Schätzer für die Kovarianzmatrix singulär ist und daher deren Inverse nicht gebildet werden kann.

Bei der Schätzung mit Konstante, α_{i0} , wird der Anfangswert, y_{i0} , als Schätzer für

die Konstante verwendet und vor Durchführen des „Pre-Whitening“ Verfahrens von der Zeitreihe abgezogen. Wie von Schmidt und Phillips (1992) argumentiert wird, ist bei Zutreffen der Nullhypothese der Anfangswert der beste Schätzer für die Konstante.

Folgend Breitung (2000) kann dieser Ansatz für einen individuellen linearen Trend, $\alpha_{i0} + \alpha_{i1}t$, erweitert werden. Der Schätzer für α_{i1} unter der Nullhypothese ist $\alpha_{i1} = T^{-1}(y_{iT} - y_{i0})$.

Breitung und Das (2008) untersuchen die Teststatistiken t_{rob} und t_{GLS} unter der Annahme, dass die Querschnittsabhängigkeiten durch eine Faktorenstruktur modelliert werden können. Dazu muss bei der Berechnung des Schätzers für die Kovarianzmatrix die Faktorenstruktur beachtet werden $\Omega = \Lambda\Lambda' + \Sigma$, wobei Λ die Matrix der Faktorenladungen und Σ die Kovarianzmatrix der idiosynkratischen Komponenten ist. Beide Schätzer können durch die Methode der Hauptkomponenten geschätzt werden.

5.4.6 Vergleich der Tests

Chang (2002) verwendet integrierbare Funktionen als Instrumente für ihren IV-Schätzer, Shin und Kang (2006) hingegen verwenden eine Signumfunktion. Zusätzlich führen Shin und Kang (2006) eine Methode ein, um starke Querschnittskorrelationen zu behandeln indem die entsprechenden Instrumente auf ihr Vorzeichen reduziert werden. Diese Methode kann nach Simulationsergebnissen von Shin und Kang (2006) in den entsprechenden Fällen die Größenverzerrungen der Teststatistiken vermeiden.

Die Prozeduren von Lopez (2009) und Breitung und Das (2005) basieren auf einer GLS-Schätzung. Lopez (2009) verwendet das Prinzip von Elliott, Rothenberg und Stock (1996), um die Querschnittsabhängigkeiten zu schätzen. Breitung und Das (2005) entwickeln ein neues Verfahren, welches vor allem die kurzfristigen Dynamiken der Querschnittskorrelationen schätzen kann. Außerdem geben sie eine robuste Version des Dickey Fuller Schätzers an.

Die Monte Carlo Simulationen von Breitung und Das (2005) zum Vergleich ihres GLS-Schätzers, ihrer robusten Teststatistik und des IV-Schätzers von Chang (2002) zeigen allgemein, dass die Macht der Tests mit der Größe von T und N steigt. Für kleine Werte von T ist der GLS-Schätzer überdimensioniert, da die Schätzung der

Kovarianzmatrix der Residuen ungenau ist. Je größer T im Verhältnis zu N ist, umso genauer wird der Test.

Für den robusten Schätzer hingegen liegt für kleine Werte von T die Macht des Tests an der Signifikanzgrenze. Außerdem hat der t_{rob} -Test größere Macht als der IV-Schätzer in allen Spezifikationen.

Die Simulationsergebnisse von Im und Pesaran (2003) zeigen, dass die Macht des IV-Schätzers von Chang (2002) davon abhängig ist, ob die Modelle einen linearen Trend enthalten oder nicht. Wird die Schätzung ohne Trend durchgeführt, ist die Macht des IV-Schätzers höher als die des IPS-Schätzers. Beinhaltet die Schätzung einen linearen Trend dreht sich das Verhältnis um. Chang (2002) führt in ihrem Artikel keine Simulationen für Modelle mit einem linearen Trend durch.

Weiter kritisieren Im und Pesaran (2003), dass Chang (2002) in ihren Simulationen nur schwache Querschnittskorrelationen zulässt. Treten starke Abhängigkeiten zwischen den Querschnittseinheiten auf, zeigen die Simulationsergebnisse von Im und Pesaran (2003) und Shin und Kang (2006), dass der IV-Schätzer stark größenverzerrt ist.

5.4.7 Die NAMEA Testergebnisse

Die Teststatistiken des robusten Schätzers von Breitung und Das (2005) (t_{rob}), des Schätzers von Jönsson (2005) (t_{PCSE}) und des IV-Schätzers von Chang (2002) werden für die Modelle mit Konstante in der Tabelle 5.6 und für die Modelle mit Konstante und linearem Trend in der Tabelle 5.6 präsentiert.

Für die IV-Schätzung von Chang (2002) werden die beiden folgenden Instrumente zur Durchführung verwendet: Der erste Schätzer ist: $F(x_{it-1})_1 = x_{it-1}e^{-c_i|x_{it-1}|}$ mit $c_i = 3T^{1/2}s_i$ und s_i der Standardabweichung von Δx_{it} . Beim zweiten handelt sich im Prinzip um einen restringierten OLS-Schätzer für das Intervall $[-K, K]$: $F(x_{it-1})_2 = x_{it-1}I\{|x_{it-1}| \leq K\}$, wobei $K = 3$ gewählt wurde. Die entsprechenden Schätzungen werden mit t_{IV1} und t_{IV2} in den Tabellen bezeichnet. Da N im Vergleich zu T nicht sehr klein ist, ist die Aussagekraft der Ergebnisse des Tests von Chang (2002) sehr kritisch zu betrachten.

Die kritischen Werte für die Modelle mit Konstante und die Modelle mit Konstante und linearem Trend zu einem Signifikanzniveau von 5% sind für den Unit Root Test von Breitung und Das (2005) $-1,79$ mit $N = 15$, für den Test von Jönsson

(2005) $-1,79$ und für den Test von Chang (2002) $-1,645$.

In der Tabelle 5.6 sind die Testergebnisse für die Modelle mit Konstante tabelliert. Bei Betrachtung der Variablen Bruttowertschöpfung und Produktionswert pro Erwerbstätigen und deren Quadrate ist zu erkennen, dass drei der vier Nullhypothesen angenommen werden. Die Instrumentenvariablenschätzer können für die dritte Potenz der beiden Variablen nicht durchgeführt werden. Bei der dritten Potenz des Produktionswerts werden die Nullhypothesen beider verbleibender Teststatistiken angenommen und bei der dritten Potenz der Bruttowertschöpfung wird die Nullhypothese für die t_{PCSE} -Statistik abgelehnt und für t_{rob} -Statistik angenommen. Für die Luftschadstoffemissionen Kohlenmonoxid, Methan, Schwefeldioxid und Stickoxid werden die Nullhypothesen für drei der vier Teststatistiken angenommen. Für Kohlendioxid gilt, dass die Hälfte der Nullhypothesen der Existenz einer Einheitswurzel verworfen wird.

Die Tabelle 5.7 der Modelle mit Konstante und linearem Trend zeigt, dass für die Bruttowertschöpfung und den Produktionswert pro Erwerbstätigen drei der vier Nullhypothesen der Existenz einer Einheitswurzel verworfen werden. Auch für die Modelle mit Konstante und linearem Trend sind die Instrumentenvariablenschätzer für die dritte Potenz der beiden Variablen nicht durchführbar, die Nullhypothese der verbleibenden zwei Teststatistiken wird verworfen. Für die Quadrate gilt, dass beide Instrumentenvariablenschätzer die Nullhypothese annehmen, die anderen zwei Teststatistiken diese verwerfen. Auch für die Luftschadstoffemissionen Kohlenmonoxid, Methan, Schwefeldioxid und Stickoxid werden dieselben Testentscheidungen getroffen. Betrachtet man Kohlendioxid werden drei der vier Nullhypothesen verworfen.

5.5 Folgerungen aus den Ergebnissen der Einheitswurzeltests

Die Untersuchung der Stationarität für den Paneldatensatz der NAMEA hat sich als Schwierig herausgestellt. Kleine Veränderungen in den Annahmen führen zu stark veränderten Testergebnissen. Da die Länge der einzelnen Zeitreihen sehr kurz ist, kann es bei der Durchführung der Teststatistiken zu Problemen kommen.

Die Testergebnisse der Einheitswurzeltests der ersten Generation unterscheiden

Tabelle 5.6: Die Testergebnisse der Modelle mit Konstante

Variable	t_{rob}	t_{PCSE}	t_{IV1}	t_{IV2}
$\log(\frac{BW}{EW})$	0,78429538	-1,79128	-0,11830448	0,43306529
$\log(\frac{BW}{EW})^2$	0,78145760	-1,79245	-0,14589978	1,4000746
$\log(\frac{BW}{EW})^3$	0,95080141	-1,79274	—	—
$\log(\frac{Prod}{EW})$	3,7627532	-1,13785	0,052728657	-2,4710004
$\log(\frac{Prod}{EW})^2$	3,8341895	-1,11611	-1,3409360	-4,8685016
$\log(\frac{Prod}{EW})^3$	3,8430146	-1,1019	—	—
$\log(\frac{CO}{EW})$	1,2532962	-1,37592	0,10311392	-3,1394160
$\log(\frac{CO2}{EW})$	0,91016087	-1,81645	0,10176696	-3,7608052
$\log(\frac{CH4}{EW})$	-0,155896	-1,37337	0,069078153	-2,3931083
$\log(\frac{SO2}{EW})$	-0,91131042	-2,78363	0,83758946	-0,92296219
$\log(\frac{NOx}{EW})$	1,2521019	-1,82644	0,018790891	-1,1707397

Tabelle 5.7: Die Testergebnisse der Modelle mit Konstante und linearem Trend

Variable	t_{rob}	t_{PCSE}	t_{IV1}	t_{IV2}
$\log(\frac{BW}{EW})$	-2,5080246	-3,66762	0,12231922	-3,1138682
$\log(\frac{BW}{EW})^2$	-2,5880944	-3,66448	4,4482604	3,0319317
$\log(\frac{BW}{EW})^3$	-2,6698807	-3,65795	—	—
$\log(\frac{Prod}{EW})$	-2,9113914	-4,36685	0,076311233	-1,8781796
$\log(\frac{Prod}{EW})^2$	-2,8786978	-4,32226	0,17397066	19,065160
$\log(\frac{Prod}{EW})^3$	-2,8316912	-4,27308	—	—
$\log(\frac{CO}{EW})$	-3,1093977	-4,44018	0,078871163	2,8775627
$\log(\frac{CO2}{EW})$	-2,9727422	-4,63809	0,40947918	-5,0441692
$\log(\frac{CH4}{EW})$	-3,7239974	-3,78653	-0,11499311	4,8806747
$\log(\frac{SO2}{EW})$	-5,2032706	-4,73679	0,86621410	1,1839644
$\log(\frac{NOx}{EW})$	-3,7364455	-5,0397	-0,67654296	0,55152180

sich kaum von den Testergebnissen der Einheitswurzeltests der zweiten Generation. Es kommt daher anders als erwartet zu keiner merklichen Verbesserung durch die Beachtung der Querschnittskorrelationen bei der Durchführung der Tests. Die Tests liefern kein eindeutiges Ergebnis, ob die Daten stationär sind oder nicht. Die Testentscheidung hängt außerdem stark von der Modellspezifikation ab.

Im Modell mit Konstante und linearem Trend werden für die Einheitswurzeltests der ersten Generation fast alle Nullhypothesen verworfen. Die Tests von Jönnson (2005) und Breitung und Das (2005) der Unit Root Tests der zweiten Generation im Modell mit Konstante und Trend verwerfen die Nullhypothese der Existenz einer Einheitswurzel für alle Variablen. Bei der Anwendung des Tests von Chang (2002) kommt es zur Annahme der Nullhypothese für fast alle Variablen für beide Instrumente.

Für den Faktoren Ansatz gilt wegen der geringen Anzahl an Perioden und Querschnittseinheiten, dass nicht garantiert werden kann, dass die Anzahl der gemeinsamen Faktoren richtig ermittelt wurde. Ein Kritikpunkt an diesem Ansatz ist, dass immer zumindest ein gemeinsamer Faktor existieren muss. Die Ergebnisse dieses Kapitels sind daher kritisch zu betrachten. Im Modell mit Konstante und linearem Trend werden drei der vier Nullhypothesen, dass die idiosynkratischen Komponenten Unit Root-stationär sind, verworfen. Das Testergebnis für die gemeinsamen Faktoren zeigt, dass diese mit Ausnahme der Bruttowertschöpfung pro Erwerbstätigen und ihrer höheren Potenzen nicht stationär sind. Es kann hier allerdings nur ein Test durchgeführt werden und es ist kein Vergleich mit anderen Ansätzen möglich.

Aus diesen Ergebnissen lässt sich schließen, dass die Nullhypothese der Modellspezifikation mit Konstante und linearem Trend abgelehnt wird. Die Daten besitzen daher laut dieser Modellspezifikation keinen stochastischen Trend.

Bei der Modellvariante mit Konstante ist das Bild nicht so eindeutig. Für den Faktoren Ansatz werden wieder drei der vier Nullhypothesen der Existenz einer Einheitswurzel in den idiosynkratischen Komponenten verworfen. Der gemeinsame Faktor ist nun zusätzlich zur Bruttowertschöpfung auch für Kohlenmonoxid und Stickoxid stationär. Der Test von Breitung und Das (2005) und das erste Instrument des Schätzers von Chang (2002) verwerfen die Nullhypothese für fast alle Variablen. Die weiteren Unit Root Tests der zweiten Generation nehmen die Nullhypothese für alle Variablen an. Die Einheitswurzeltests der ersten Generation liefern ein

gemischtes Bild. Die Nullhypothese wird für die ökonomischen Variablen, Kohlendioxid und Stickoxid häufiger angenommen, für Methan, Kohlenmonoxid und Schwefeldioxid öfter verworfen.

Aus diesen Ergebnissen kann daher nicht eindeutig geschlossen werden, ob die Daten stationär sind.

Betrachtet man die Abbildung 3.1, ist zu erkennen, dass die indextierten jährlichen Mittel der Variablen Methan, Schwefeldioxid und Kohlenmonoxid einen negativen Trend haben und die restlichen Variablen einen positiven. Daher trifft für die betrachteten Daten besser die Modellspezifikation mit Konstante und linearem Trend zu. Für diese wird die Nullhypothese aber öfter verworfen und die Zeitreihen weisen daher einen deterministischen linearen Trend auf. Da der Beobachtungszeitraum sehr kurz ist kann davon ausgegangen werden, dass sich die Technologie der Produktion kaum verändert hat. Der Trend entsteht daher durch die Wachstumsrate der Produktion. Die Wachstumsrate wird in einem gewissen Sinn durch das Logarithmieren der Daten kompensiert.

Die durchgeführten Einheitswurzeltests sind nicht eindeutig im Stande zu klären, ob die Daten stationär sind oder nicht. Es ist unbedingt notwendig weitere Forschung durchzuführen. Dafür werden neue Techniken benötigt, um auch einen Datensatz wie die NAMEA Österreich eindeutig auf Stationarität untersuchen zu können.

Kapitel 6

Schätzung der Umwelt Kuznets Kurve für Österreich

Die EKC Hypothese wird für die fünf Luftschadstoffemissionen Kohlenmonoxid, Kohlendioxid, Methan, Stickoxid und Schwefeldioxid auf Grundlage eines Panel-datensatzes auf sektoriellem Niveau, der NAMEA Österreich, überprüft.

Der Vorteil dieses Datensatzes ist, dass er eine hohe Heterogenität aufweist und so neue Einblicke in das Verständnis des Einkommens - Umweltverhältnisses geben kann.

Da es sich bei der NAMEA Österreich um Daten der Wirtschaftssektoren handelt, spiegelt die betrachtete Entwicklung der Luftschadstoffemissionen nicht die Entwicklung für die gesamte Wirtschaft wieder. Das Verhalten der Privaten Haushalte wird ausgegliedert.

Zunächst muss die Modellspezifikation definiert werden.

Die Grundlage für die Schätzung der EKC Kurve für Österreich bildet das Modell (2.1). Da es sich im Unterschied zu den EKC Analysen auf Makroniveau bei der NAMEA Österreich um sektorenspezifische Daten handelt, wird das BIP durch die Bruttowertschöpfung und die Population durch die Erwerbstätigen in Vollzeitäquivalenten ersetzt. Für den Umweltindikator wird der entsprechende Luftschadstoff eingesetzt, wobei dieser durch die Erwerbstätigen in Vollzeitäquivalenten dividiert wird, um eine Schätzung des Schadstoffausstoßes pro Einheit zu erhalten. Damit ergibt sich das folgende Modell:

$$\ln\left(\frac{E_{it}}{EW_{it}}\right) = \alpha_i + \gamma + \beta_1 \ln\left(\frac{BW_{it}}{EW_{it}}\right) + \beta_2 \ln\left(\frac{BW_{it}}{EW_{it}}\right)^2 + \beta_3 \ln\left(\frac{BW_{it}}{EW_{it}}\right)^3 + \varepsilon_{it} \quad i = 1, \dots, N(6.1)$$

Das Modell wird für die lineare, quadratische und kubische Beziehung zwischen Umweltindikator und Einkommen getestet.

Wie in der Literatur der Panelmodelle üblich wird das „Random und das Fixed Effects“ Modell geschätzt. Mit der Hausman-Teststatistik wird auf einem Signifikanzniveau von 5% entschieden, ob für den gewählten Luftschadstoff das RE oder das FE Modell zutrifft.

Besondere Aufmerksamkeit wird der Kontrolle der Daten auf Autokorrelation und Heteroskedastizität geschenkt. Die Autokorrelation wird durch einen AR(1)-Prozess geschätzt, da es sich bei den Beobachtungen um jährliche Daten handelt. Gretl bietet die Möglichkeit für das „Fixed Effects“ und das gepoolte Modell robuste Schätzer zu verwenden, um die Konsistenz in Bezug auf Autokorrelation und Heteroskedastizität zu garantieren. Zur robusten Schätzung gibt es zwei Verfahren zur Auswahl, das Prinzip von Arellano (2003) und das Prinzip von Beck und Katz (1995). Bei Arellano (2003) handelt es sich um „Heteroskedasticity and Autocorrelation Consistent (HAC)“ Schätzer. Der Schätzer von Beck und Katz (1995) eignet sich für Panels, in denen Autokorrelation vernachlässigt werden kann. Dieser Schätzer zieht die Querschnittskorrelation und die Heteroskedastizität für jede Querschnittseinheit in Betracht. Für die Schätzungen der NAMEA Österreich wird die HAC Methode verwendet.

Da die periodenspezifischen Konstanten meist nicht signifikant von Null verschieden sind und die Schätzung der Modelle ohne γ_i die gleichen Ergebnisse liefert, werden sie in der weiteren Analyse nicht beachtet.

Tabelle 6.1: Grundlegende Statistiken der Variablen von 1995-2007

Variable	arithmetisches Mittel	Minimum	Maximum
$\frac{BW}{EW}$	73479	14027,5	200784
$\frac{Prod}{EW}$	206320	28784,5	828054
$\log\left(\frac{BW}{EW}\right)$	11,081	9,5488	12,210
$\log\left(\frac{Prod}{EW}\right)$	12,050	10,268	13,627
$\log\left(\frac{CO}{EW}\right)$	-2,5409	-5,5070	2,0525
$\log\left(\frac{CO_2}{EW}\right)$	3,4202	0,33738	6,5040
$\log\left(\frac{CH_4}{EW}\right)$	-5,6892	-9,9154	0,14626
$\log\left(\frac{SO_2}{EW}\right)$	-4,5783	-8,2400	-1,5901
$\log\left(\frac{NO_x}{EW}\right)$	-2,5744	-5,4325	1,1504

Die Variablen Bruttowertschöpfung und Produktionswert pro Erwerbstätigen sind in € angegeben. Bei den anderen Variablen handelt es sich um die logarithmierten Werte.

Im Anschluss wird die Variable Bruttowertschöpfung durch die Variable Produkti-

onswert ersetzt, da beide Variablen in der Praxis als erklärende Variable verwendet werden.

Der Produktionswert entspricht dem Gesamtwert der im Produktionsprozess erzeugten Waren und Dienstleistungen, zieht man von diesem die Vorleistungen ab, so erhält man die Bruttowertschöpfung. Vorleistungen werden durch den Wert der im Produktionsprozess verbrauchten, verarbeiteten oder umgewandelten Waren definiert.

Da es sich bei der NAMEA um einen mikroökonomischen Datensatz handelt, spricht für die Verwendung des Produktionswertes pro Erwerbstätigen als Regressor, dass er den Gesamtwert der Produktion für die einzelnen Sektoren misst. In Studien auf sektoriellem Niveau ist immer der gesamte Wert der Produktion eines Sektors relevant. Zukäufe von Waren und Dienstleistungen eines Sektors von anderen sind üblich. Für einen Sektor kann ein Produkt als Endprodukt bezeichnet werden, wenn die Produktion des Gutes in diesem Sektor abgeschlossen ist. Es ist egal, ob dieses Produkt in der Folge verbraucht wird oder von einem anderen Sektor weiterverarbeitet wird. Die Weiterverarbeitung in einem anderen Sektor kann als unabhängige Produktion betrachtet werden. Der Schadstoffausstoß, welcher bei der Produktion eines Gutes entsteht, wird dem entsprechenden Sektor zugewiesen und die Messung der Schadstoffemissionen erfolgt für jeden Sektor getrennt. Dabei ist es egal, ob die Emission bei der Verarbeitung eines Rohstoffs oder bei der Weiterverarbeitung entsteht.

Wird die gesamte Wirtschaft eines Landes auf Makroniveau untersucht, ändert sich diese Betrachtungsweise. Auf makroökonomischem Niveau ist es nicht üblich den Wert der Vorleistungen mitzuzählen, da die Wirtschaftsleistung gesamt betrachtet wird. Die Produktion und Weiterverarbeitung der Güter erfolgt sozusagen im „gleichen Sektor“. Daher wird für derartige Datensätze häufiger die Bruttowertschöpfung als Regressor verwendet.

Ein Beispiel soll Klarheit schaffen: Der Sektor Holzverarbeitung schneidet Holz zu, welches im Anschluss an den Sektor Papier und Druck verkauft wird. Ist das Holz fertig geschnitten, ist die Produktion im Sektor Holzverarbeitung abgeschlossen. Er verkauft das Holz an die Papierindustrie, welche mit dem Holz Druckpapier herstellt. Beide Produktionsvorgänge sind auf sektoriellem Niveau voneinander unabhängig und abgeschlossen. Der Wert der jeweiligen Produktion und der dabei entstehende Schadstoffausstoß werden in einer Schätzung auf mikroökonomischem Niveau für die beiden Sektoren getrennt gemessen. Das passiert durch die Verwendung des Produktionswerts als Prädiktor. Gesamtwirtschaftlich betrachtet

wird aus dem verwendeten Holz in einem Vorgang Papier hergestellt. Durch die Bruttowertschöpfung wird der Wert der Papierproduktion ohne die Vorleistung des Sektors Holzverarbeitung gemessen.

Es werden Schätzungen für beide Variablen als Prädiktor durchgeführt. In diesem Zusammenhang können mögliche Unterschiede der Schätzungen in Bezug auf die beiden abhängigen Variablen untersucht werden.

Zusätzlich werden die Daten in die Module Landwirtschaft, Industrie inklusive Bauwirtschaft und Dienstleistung aufgespalten. Diese Teilbereiche entsprechen den primären, sekundären und tertiären Wirtschaftssektoren. Für diese wird die EKC Hypothese einzeln getestet. In diesem Zusammenhang wird untersucht, ob sich das Gesamtbild in den Teilbereichen widerspiegelt oder ändert. Im Speziellen ist der Vergleich zwischen dem abnehmenden Landwirtschaftssektor und dem boomenden Dienstleistungssektor interessant. Ein Nachteil der Schätzung dieser Teilbereiche ist, dass die Beobachtungsanzahl verringert wird und die Ergebnisse daher an Signifikanz verlieren können.

Trifft die EKC Hypothese zu, wird der Wendepunkt berechnet. Dieser gibt an, wann der maximale Schadstoffausstoß in Bezug auf die Produktion erreicht wird bzw. wann er bereits erreicht wurde. Er berechnet sich durch:

$$WP = e^{-\frac{\hat{\beta}_1}{2\hat{\beta}_2}}, \quad (6.2)$$

wobei $\hat{\beta}_1$ und $\hat{\beta}_2$ die geschätzten Koeffizienten des EKC Modells sind. Der Wendepunkt kann für die quadratischen und kubischen Spezifikationen berechnet werden.

Im Folgenden werden die Testergebnisse der fünf Luftschadstoffemissionen für alle produzierenden Sektoren, sowie Landwirtschaft, Industrie inklusive Bauwirtschaft und Dienstleistung präsentiert und analysiert. Es wird jeweils für die erklärenden Variablen Bruttowertschöpfung und Produktionswert dividiert durch die Anzahl der Erwerbstätigen in Vollzeitäquivalenten eine Tabelle mit dem der Luftschadstoffemission am besten entsprechenden Modell angegeben. Gegebenenfalls wird der Wendepunkt bzw. werden die Wendepunkte berechnet.

Bevor die Testergebnisse analysiert werden, wird noch ein Überblick über ähnliche EKC Studien gegeben.

Mazzanti, Montini und Zoboli (2008) führen eine Analyse auf sektoriellem Niveau basierend auf der NAMEA Italien durch. Analysiert werden neun Luftschadstoffemissionen unterteilt in 29 Wirtschaftssektoren für den Zeitraum 1990-2001. Es werden die Sektoren gesamt betrachtet, sowie die Unterteilung der Wirtschaft nach der Drei-Sektoren Hypothese. Als unabhängige Variablen werden die Bruttowertschöpfung und der Produktionswert dividiert durch die Erwerbstätigen, wie bei der NAMEA Österreich, verwendet. Die Ergebnisse für die Bruttowertschöpfung als Prädiktor liefern sogar Anzeichen für die Existenz der EKC Hypothese für Treibhausgase. Im Detail finden sie inverse U-förmige Verläufe des Wirtschaft-Umwelt Verhältnisses für die Luftemissionen CO₂, N₂O, NO_x und NH₃ mit Wendepunkten innerhalb der beobachteten Bruttowertschöpfung und N-förmige Verläufe für CH₄, SO_x, CO und PM₁₀. Beim Übergang zum Produktionswert als Prädiktor ändern sich die Ergebnisse für N₂O und CO₂. Da die Arbeit von Mazzanti, Montini und Zoboli (2008) der in dieser Arbeit durchgeführten Analyse sehr ähnlich ist, wird ein Vergleich der beiden Länder durchgeführt.

EKC Analysen eines Landes auf provinzialem Niveau gibt es für China, die USA und die Türkei.

Die Studie von de Groot, Withagen und Minliang (2001) für 30 Provinzen in China von 1982-1997 untersucht die Verschmutzung des Abwassers, die gesamten Luftemissionen und den Abfallstoff auf die Existenz der EKC. Die Umweltindikatoren werden für die Schätzung der Modelle absolut, relativ und produktionsorientiert gemessen. Die Analyse auf provinziellem Niveau ist interessant, da die Provinzen Chinas sehr unterschiedlich entwickelt sind und es sich bei China gesamt um eine stark wachsende Wirtschaft mit stark verschmutzter Umwelt handelt. Die Ergebnisse zeigen, dass es große Unterschiede für die nördlichen und südlichen, sowie für die Provinzen mit Meerzugang und die ländlichen Provinzen gibt. Die nördlichen, ländlichen Provinzen gelten als die weniger entwickelten, auch der Grad der Umweltverschmutzung ist in diesen Teilen des Landes weniger gravierend. Diese Unterschiede werden auf die zentralistische Regierung Chinas zurückgeführt. Seit Anfang der 80er Jahre wird vor allem die leichte Industrie gefördert, welche in den südlichen Provinzen stärker lokalisiert ist. Außerdem werden die Provinzen mit Meerzugang durch den starken Ausbau der Häfen gefördert. Die Ergebnisse zeigen einen monotonen Rückgang des Abwassers bei steigender Produktion. Für die Luftemissionen wird bei der Messung der Emissionen pro Kopf ein monotoner Anstieg und bei der produktionsorientierten Messung ein monotoner Rückgang

beobachtet. Bei der Niveaumessung tritt der typische EKC Verlauf auf. Für den Abfallstoff wird keine konsistente Schätzung gefunden.

Aldi (2005) untersucht auf dem Niveau der 50 US Staaten die Unterschiede der EKC Kurve basierend auf Konsum und Produktion für CO₂ von 1960-1999. Seine Ergebnisse zeigen, dass die konsumbasierten EKC Kurven höhere Wendepunkte als die produktionsbasierten EKC Kurven aufweisen.

Akbostanci, Türüt-Asik und Tunc (2009) untersuchen die Luftschadstoffemissionen von CO₂ und PM₁₀ für 58 Provinzen der Türkei von 1992-2001. Für beide werden N-förmige Kurvenverläufe gefunden, wobei mehr als die Hälfte der Provinzen einen Produktionswert aufweisen, welcher sich im ersten und zweiten Drittel der N-förmigen Kurve befindet. Nur wenige Provinzen finden sich im dritten Bereich der Kurve, in welchem die Emissionen mit wachsender Wirtschaft wieder steigen. Vor der Schätzung der Modelle werden Unit Root Tests durchgeführt, um den Pannedatensatz auf Stationarität zu untersuchen. Dazu werden die Einheitswurzeltests der ersten Generation angewendet.

Zusätzlich werden die CO₂ Emissionen für die Türkei gesamt von 1968-2003 untersucht. Im betrachteten Zeitraum ist das Verhältnis der Emission und des Wirtschaftswachstums monoton steigend.

Es gibt einige Studien, welche die Luftschadstoffemissionen für ein Land gesamt betrachten.

Für Österreich gibt es von Friedl und Getzner (2003) eine Untersuchung für CO₂ für den Zeitraum 1960-1999. Es wird eine N-förmige Kurve gefunden.

Egli (2002) untersucht basierend auf einem Datensatz von 1966-1998 die Luftschadstoffemissionen von SO₂, NO_x, CO₂, CO, NH₃, CH₄, PM und NMVOC für Deutschland. Die Studie von Roca, Padilla, Farre und Galletto (2001) schätzen die EKC Kurve für sieben Luftemissionen in Spanien von 1980-1996.

Weitere erwähnenswerte EKC Studien für ein Land sind: Die Analyse von CO₂ und SO₂ für Tunesien für die Jahre 1961-2004 von Fodha und Zaghoudund (2010), welche sich mit den statistischen Eigenschaften der EKC Kurve auseinandersetzen und Unit Root und Kointegrationstests durchführen. Die Studie von Kunnas und Myllyntaus (2010) untersucht die SO₂ Entwicklung Finnlands im späten 20ten Jahrhundert und erweitert die Analyse der EKC in verschiedene Richtungen, welche den Zusammenhang der SO₂ Emissionen und der wirtschaftlichen Entwicklung in Finnland erklären könnten. Die Analyse der CO₂ Emissionen Kanadas von He und Richard (2010) beschäftigt sich mit der parametrischen Struktur der EKC.

6.1 Die NAMEA Testergebnisse

6.1.1 Alle produzierenden Sektoren

In der Tabelle 6.2 befinden sich die Schätzungen der Modelle aller Luftschadstoffemissionen für alle produzierenden Sektoren mit Bruttowertschöpfung dividiert durch die Anzahl der Erwerbstätigen als erklärende Variable.

Die Luftemissionen Kohlendioxid und Stickoxid gemessen pro Erwerbstätigen werden monoton wachsend mit steigender Bruttowertschöpfung pro Erwerbstätigen modelliert.

Der Kurvenverlauf von Schwefeldioxid ist U-förmig. Der Schadstoffausstoß nimmt zunächst mit der Bruttowertschöpfung pro Erwerbstätigen ab bis der Wendepunkt von 156246,6 € erreicht ist. Danach steigt der Schadstoffausstoß wieder an. Erst die drei Sektoren Bergbau, Papier und Druck und Energieverbrauch haben im betrachteten Zeitraum den Wendepunkt überschritten und ihre Schadstoffemission nimmt infolge mit wachsender Bruttowertschöpfung pro Erwerbstätigen zu.

Die Schadstoffentwicklung von Methan und Kohlenmonoxid in Bezug auf die Bruttowertschöpfung pro Erwerbstätigen wird durch eine N-förmige Kurve beschrieben. Der Ausstoß von CH₄ nimmt in den Sektoren bis zu einer Bruttowertschöpfung pro Erwerbstätigen von 241,4€ zu und fällt dann, bis die Bruttowertschöpfung pro Erwerbstätigen von 14,4Mio € erreicht wird, danach nimmt die Schadstoffkonzentration wieder zu. Für den betrachteten Zeitraum befinden sich die einzelnen Sektoren auf dem mittleren, fallenden Bereich der N-förmigen Kurve. Das bedeutet, dass bei steigender Bruttowertschöpfung pro Erwerbstätigen der Ausstoß von Methan sinkt. Daher trifft für Methan in einem gewissen Sinn die EKC Hypothese zu. Auch für Kohlenmonoxid gilt, dass für den betrachteten Zeitraum die Beobachtungen der Bruttowertschöpfung pro Erwerbstätigen zwischen den beiden Wendepunkten liegen und daher die Emission von CO mit steigender Bruttowertschöpfung pro Erwerbstätigen fällt.

Die Tabelle 6.3 enthält die Schätzungen der Luftschadstoffemissionen mit dem Produktionswert pro Erwerbstätigen als Prädiktor.

Methan gemessen pro Erwerbstätigen wird durch ein lineares Modell mit wachsender Schadstoffkonzentration beschrieben. CO₂, SO₂ und NO_x werden durch quadratische Funktionen modelliert. Der Kurvenverlauf von Schwefeldioxid pro Erwerbstätigen ist U-förmig. Jene von Stickoxid und Kohlendioxid folgen dem Verlauf der EKC Kurve. Für CO₂ gilt, dass sich die Beobachtungen des Produkti-

Tabelle 6.2: Die Schätzungen aller produzierenden Sektoren für die Bruttowertschöpfung pro Erwerbstätigen als Regressor

Luftschadstoff	Parameter	HAC t-Statistik	Hausman Statistik	Modellspezifikation	F-Test Breusch-Pagan	Korrigiertes R^2	Wendepunkt(e)	Kurvenverlauf
Kohlendioxid	α	-2,67224***	4,97801	FEM	713,46	0,987306		Linear
	β_1	0,549823***						
Kohlenmonoxid	α	-768,331***	14,0723	FEM	969,548	0,990373	237,98	N-förmig
	β_1	210,505***					14,09Mio	
	β_2	-19,2340***						
	β_3	0,584227***						
Methan	α	-438,591***	33,0671	FEM	998,643	0,994336	241,4	N-förmig
	β_1	118,558***					14,46Mio	
	β_2	-10,8046***						
	β_3	0,327677***						
Schwefeldioxid	α	60,4732**	24,9613	FEM	206,237	0,961624	156246,6	U-förmig
	β_1	-10,9589**						
	β_2	0,458179**						
Stickoxid	α	-8,28805***	1,02185	REM	1349,55			Linear
	β_1	0,515633***						

Die präsentierten t-Statistiken der Koeffizienten wurden mit der HAC Methode ermittelt. Sie sind konsistent in Bezug auf Autokorrelation und Heteroskedastizität.

* kennzeichnet Signifikanz zu einem Niveau von 10%, ** zu 5% und *** zu 1%. Die Hausman-Statistik entscheidet zwischen „Fixed Effects und Random Effects“ Modell zu einem Signifikanzniveau von 5%. FEM steht für „Fixed Effects“ Modell und REM für „Random Effects“ Modell. Die Spalte „F-Test Breusch-Pagan“ festet das Modell auf unterschiedliche Konstanten, im Fall des „Fixed Effects“ Modell mit einem einfachen F-Test und im Fall des „Random Effects“ mithilfe des Tests von Breusch-Pagan. Die Wendepunkte sind in € angegeben. Alle Schätzungen wurden in Gretl durchgeführt.

Tabelle 6.3: Die Schätzungen aller produzierenden Sektoren für den Produktionswert pro Erwerbstitigen als Regressor

Luftschadstoff	Parameter	HAC t-Statistik	Hausman Statistik	Modellspe- zifikation	F-Test Breusch-Pagan	Korrigiertes R^2	Wendepunkt(e)	Kurven- verlauf
Kohlendioxid	α	-56,3724***	5,23173	REM	1208,62		758181,7	EKC
	β_1	8,96117***						
	β_2	-0,330947***	-5,142					
Kohlenmonoxid	α	-586,605***	9,09991	FEM	989,791	0,989927	421,02	N-förmig
	β_1	145,435***	5,441				78821572,2	
	β_2	-12,0340***	-5,512					
	β_3	0,330919***	5,576					
Methan	α	-9,45735***	0,00259867	REM	1388,12			Linear
	β_1	0,312708***	3,367					
Schwefeldioxid	α	107,549***	36,8678	FEM	238,075	0,967221	458710,3	U-förmig
	β_1	-17,3433***	-3,286					
	β_2	0,665199***	3,216					
Stickoxid	α	-54,2573***	2,80918	REM	1304,32		933934,5	EKC
	β_1	7,65222***	5,538					
	β_2	-0,278320***	-5,014					

Die präsentierten t-Statistiken der Koeffizienten wurden mit der HAC Methode ermittelt. Sie sind konsistent in Bezug auf Autokorrelation und Heteroskedastizität.

* kennzeichnet Signifikanz zu einem Niveau von 10%, ** zu 5% und *** zu 1%. Die Hausman-Statistik entscheidet zwischen „Fixed Effects und Random Effects“.

Modell zu einem Signifikanzniveau von 5%. FEM steht für „Fixed Effects“ Modell und REM für „Random Effects“ Modell. Die Spalte „F-Test Breusch-Pagan“ festet

das Modell auf unterschiedliche Konstanten, im Fall des „Fixed Effects“ Modell mit einem einfachen F-Test und im Fall des „Random Effects“ mithilfe des Tests von

Breusch-Pagan. Die Wendepunkte sind in € angegeben. Alle Schätzungen wurden in Gretl durchgeführt.

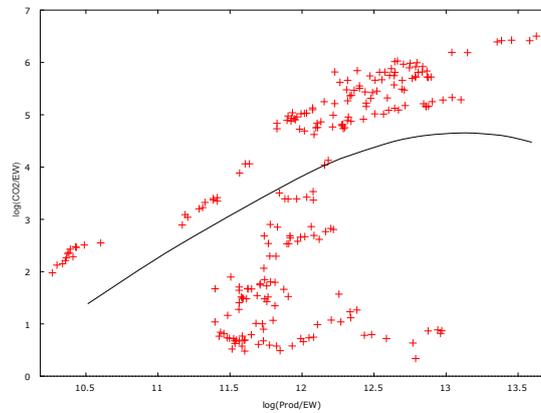


Abbildung 6.1: Die EKC Kurve für CO2 von 1995-2007

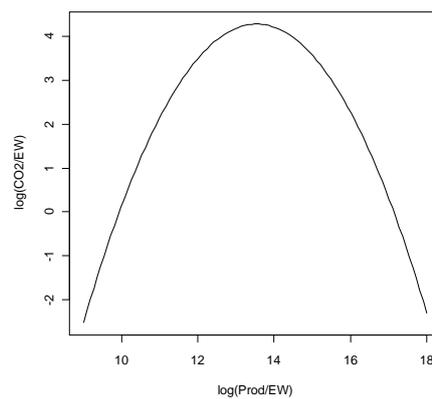


Abbildung 6.2: Die theoretische EKC Kurve für CO2

onswertes pro Erwerbstätigen der einzelnen Sektoren am steigenden Ast bzw. nahe des Wendepunktes der EKC Kurve befinden. Die Abbildungen 6.1 und 6.2 sollen dies verdeutlichen. Sie zeigen die EKC Kurve für die beobachtete Zeitperiode und den gesamten Verlauf der EKC Kurve für CO2.

Für Stickoxid ist der Wendepunkt wesentlich höher. Alle Sektoren befinden sich für die Beobachtungsperiode noch auf dem steigenden Ast der EKC Kurve.

Die Schätzung von Kohlenmonoxid ergibt ein kubisches Modell. Beide Wendepunkte liegen außerhalb der Beobachtungen des Produktionswertes pro Erwerbs-

tätigen. Daher befinden sich alle Sektoren am abnehmenden Ast der N-förmigen Kurve. Die Abbildungen 6.3 und 6.4 sollen auch hier den Verlauf verdeutlichen. Sie zeigen den Verlauf der EKC für die Beobachtungsperiode und den theoretischen Verlauf der gesamten EKC Kurve für CO.

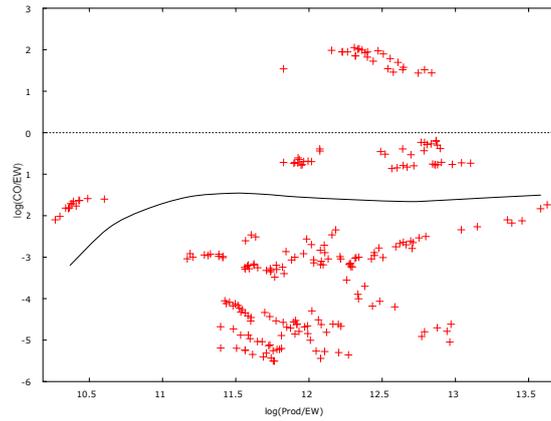


Abbildung 6.3: Die EKC Kurve für CO von 1995-2007

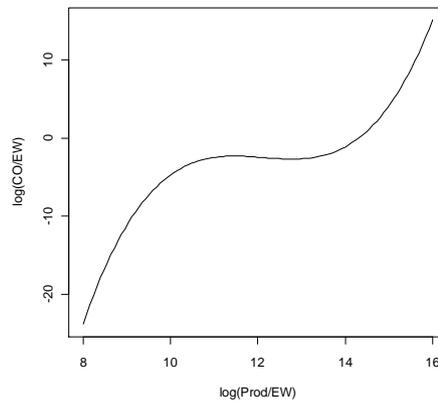


Abbildung 6.4: Die theoretische EKC Kurve für CO

6.1.2 Landwirtschaft

Da es sich bei der Landwirtschaft nur um einen einzelnen Sektor und somit um eine einfache Zeitreihe handelt, wird eine OLS Schätzung durchgeführt. Wie für das „Fixed Effects“ Modell wird ein HAC Schätzer verwendet, um eine konsistente Schätzung in Bezug auf Autokorrelation und Heteroskedastizität zu erhalten. Der Bereich umfasst nach ÖNACE Klassifikation die Sektoren Landwirtschaft, Forstwirtschaft, sowie Fischerei und Fischzucht.

Für den Sektor Landwirtschaft ergeben bei Betrachtung mit Bruttowertschöpfung dividiert durch die Erwerbstätigen (Tabelle 6.4) als Regressor die Schätzungen aller Luftschadstoffemissionen ein lineares Modell. Die Schwefeldioxidkonzentration nimmt mit zunehmender Bruttowertschöpfung pro Erwerbstätigen monoton ab. In der Landwirtschaft kann das vor allem auf die seit 1.1.2004 flächendeckende Versorgung mit schwefelfreien Kraftstoffen zurückgeführt werden.

Die Emissionen der anderen Luftschadstoffe nehmen linear mit steigender Bruttowertschöpfung pro Erwerbstätigen zu, wobei die Zunahme der Schadstoffkonzentration bei Kohlendioxid und Kohlenmonoxid stärker ausfällt.

Tabelle 6.4: Die Schätzungen der Landwirtschaft für die Bruttowertschöpfung pro Erwerbstätigen als Regressor

Luftschadstoff	Parameter	HAC t-Statistik	R^2	Kurven- verlauf
Kohlendioxid	α	-10,8160**	0,353628	Linear
	β_1	1,36448**		
Kohlenmonoxid	α	-12,6659**	0,272307	Linear
	β_1	1,13282**		
Methan	α	-5,97207***	0,840005	Linear
	β_1	0,603114***		
Schwefeldioxid	α	31,0438***	0,537446	Linear
	β_1	-3,85175***		
Stickoxid	α	-8,75777***	0,393162	Linear
	β_1	0,661599**		

Die präsentierten t-Statistiken der Koeffizienten wurden mit der HAC Methode ermittelt. Sie sind konsistent in Bezug auf Autokorrelation und Heteroskedastizität. * kennzeichnet Signifikanz zu einem Niveau von 10%, ** zu 5% und *** zu 1%. Alle Schätzungen wurden in Gretl durchgeführt.

Tabelle 6.5: Die Schätzungen der Landwirtschaft für den Produktionswert pro Erwerbstätigen als Regressor

Luftschadstoff	Parameter	HAC t-Statistik	R^2	Wendepunkt	Kurven- verlauf	
Kohlendioxid	α	-709,867***	-5,931	0,890446	38999	EKC
	β_1	134,785***	5,878			
	β_2	-6,37505***	-5,805			
Kohlenmonoxid	α	-874,376***	-9,980	0,924063	37422,2	EKC
	β_1	165,776***	9,871			
	β_2	-7,87159***	-9,784			
Methan	α	-6,42293***	-21,33	0,960584		Linear
	β_1	0,601886***	20,70			
Schwefeldioxid	α	36,3088***	7,184	0,706111		Linear
	β_1	-4,07339***	-8,320			
Stickoxid	α	-387,496***	-5,004	0,882771	38053,9	EKC
	β_1	73,0479***	4,930			
	β_2	-3,46305***	-4,887			

Die präsentierten t-Statistiken der Koeffizienten wurden mit der HAC Methode ermittelt. Sie sind konsistent in Bezug auf Autokorrelation und Heteroskedastizität. * kennzeichnet Signifikanz zu einem Niveau von 10%, ** zu 5% und *** zu 1%. Die Wendepunkte sind in € angegeben. Alle Schätzungen wurden in Gretl durchgeführt.

In der Tabelle 6.5 befinden sich die Schätzungen aller Luftschadstoffemissionen mit dem Produktionswert pro Erwerbstätigen als unabhängige Variable.

Methan wird durch ein lineares Modell mit steigender Schadstoffkonzentration und Schwefeldioxid durch ein lineares Modell mit sinkender Schadstoffkonzentration bei wachsendem Produktionswert pro Erwerbstätigen beschrieben. Der Kurvenverlauf von Kohlendioxid, Kohlenmonoxid und Stickoxid ist invers U-förmig, daher trifft für diese Emissionen die EKC Hypothese zu. Die Wendepunkte befinden sich innerhalb der Beobachtungen des Produktionswertes pro Erwerbstätigen des Sektors Landwirtschaft für die Jahre 1995-2007. Daher gilt für CO₂, CO und NO_x, dass die Schadstoffkonzentration in den letzten Jahren gesunken ist.

Die Schätzungen ändern sich für drei der fünf Modelle beim Übergang von der Bruttowertschöpfung zum Produktionswert als erklärende Variable. Die unterschiedliche Entwicklung der ökonomischen Variablen kann zur Erklärung beitragen. Der Produktionswert ist zwischen 1995-2007 gesamt um 1,3% gewachsen, die Brutto-

wertschöpfung hingegen um $-3,6\%$ gesunken.

6.1.3 Industrie inklusive Bauwirtschaft

In der Tabelle 6.6 befinden sich die Schätzungen der Luftschadstoffemissionen des Sekundärsektors Industrie inklusive Bauwirtschaft mit Bruttowertschöpfung dividiert durch die Anzahl der Erwerbstätigen als Regressor.

Der Emissionsausstoß von Kohlendioxid und Schwefeldioxid folgt einem linearen Verlauf. Für CO nimmt der Ausstoß mit steigender Bruttowertschöpfung pro Erwerbstätigen zu, für SO₂ fällt er ab.

Der Kurvenverlauf der Luftemissionen Kohlenmonoxid, Methan und Stickoxid ist N-förmig. Wie zuvor liegen die Wendepunkte außerhalb der Beobachtungen der Bruttowertschöpfung pro Erwerbstätigen für den Zeitraum 1995-2007 und die jeweiligen Luftemissionen nehmen mit wachsender Bruttowertschöpfung pro Erwerbstätigen ab. Die kubischen Spezifikationen vertreten die Hypothese der EKC Kurve.

Die Schätzungen der Luftemissionen CO₂ und NO_x mit dem Produktionswert dividiert durch die Anzahl der Erwerbstätigen als Regressor folgen dem Verlauf der EKC Kurve, wobei für beide Schadstoffe der Wendepunkt der Kurve außerhalb der Beobachtungen des Produktionswertes pro Erwerbstätigen liegt und noch nicht erreicht wurde.

Der Kurvenverlauf von Kohlenmonoxid ist U-förmig. Der Wendepunkt ist sehr niedrig und sämtliche Sektoren haben ihn bereits überschritten. Der Emissionsausstoß nimmt daher mit der Produktion pro Erwerbstätigen zu.

Wächst der Wert des Produktionswertes pro Erwerbstätigen an, so steigt der Emissionsausstoß von Methan monoton an, jener von Schwefeldioxid fällt monoton ab.

6.1.4 Dienstleistung

Wegen der geringen Anzahl an Beobachtungen können für den Tertiärsektor nur die lineare und quadratische Spezifikation des „Random und Fixed Effects“ Modells geschätzt werden.

Die Tabelle 6.8 enthält die Schätzungen der Luftemissionen für den Dienstleistungssektor mit Bruttowertschöpfung pro Erwerbstätigen als Prädiktor.

Tabelle 6.6: Die Schätzungen der Industrie inkl. Bauwirtschaft für die Bruttowertschöpfung pro Erwerbstätigen als Regressor

Luftschadstoff	Parameter	HAC t-Statistik	Hausman Statistik	Modellspezifikation	F-Test Breusch-Pagan	Korrigiertes R^2	Wendepunkt(e)	Kurvenverlauf
Kohlendioxid	α	-3,47629***	10,17	FEM	552,373	0,987722		Linear
	β_1	0,614261***	5,770					
Kohlenmonoxid	α	-1653,34***	10,4982	FEM	755,448	0,988645	254,1	N-förmig
	β_1	448,132***	5,346				17,083Mio	
	β_2	-40,4619***	-5,454					
	β_3	1,21481***	5,557					
Methan	α	-1016,28***	41,881	FEM	750,85	0,993815	258,2	N-förmig
	β_1	273,243***	2,743				17,746Mio	
	β_2	-11,0116*	-2,791					
	β_3	0,736913***	2,837					
Schwefeldioxid	α	3,57085	15,2651	FEM	219,597	0,963295		Linear
	β_1	-0,722314***	-3,736					
Stickoxid	α	-786,129***	6,43883	REM	822,618		295,5	N-förmig
	β_1	206,215***	2,782				25,1Mio	
	β_2	-18,1250	-2,763					
	β_3	0,531872***	2,751					

Die präsentierten t-Statistiken der Koeffizienten wurden mit der HAC Methode ermittelt. Sie sind konsistent in Bezug auf Autokorrelation und Heteroskedastizität.

* kennzeichnet Signifikanz zu einem Niveau von 10%, ** zu 5% und *** zu 1%. Die Hausman-Statistik entscheidet zwischen „Fixed Effects und Random Effects“

Modell zu einem Signifikanzniveau von 5%. FEM steht für „Fixed Effects“ Modell und REM für „Random Effects“ Modell. Die Spalte „F-Test Breusch-Pagan“ testet

das Modell auf unterschiedliche Konstanten, im Fall des „Fixed Effects“ Modell mit einem einfachen F-Test und im Fall des „Random Effects“ mithilfe des Tests von

Breusch-Pagan. Die Wendepunkte sind in € angegeben. Alle Schätzungen wurden in Gretl durchgeführt.

Tabelle 6.7: Die Schätzungen der Industrie inkl. Bauwirtschaft für den Produktionswert pro Erwerbstätigen als Regressor

Luftschadstoff	Parameter	HAC t-Statistik	Hausman Statistik	Modellspe- zifikation	F-Test Breusch-Pagan	Korrigiertes R^2	Wendepunkt(e)	Kurven- verlauf
Kohlendioxid	α	-47,4239***	4,16913	REM	890,746		838051,9	EKC
	β_1	7,54484***	3,451					
	β_2	-0,276594***	-3,174					
Kohlenmonoxid	α	59,7747***	3,718	REM	852,057		304142,7	U-förmig
	β_1	-9,96294***	-3,886					
	β_2	0,394564***	3,861					
Methan	α	-9,03780***	-6,820	FEM	1244,61	0,993441		Linear
	β_1	0,216974**	1,997					
Schwefeldioxid	α	3,17704	1,567	FEM	236,883	0,963381		Linear
	β_1	-0,629631***	-3,789					
Stickoxid	α	-54,6917***	-4,809	REM	948,211		812719,7	EKC
	β_1	7,70131***	4,247					
	β_2	-0,282967***	-3,916					

Die präsentierten t-Statistiken der Koeffizienten wurden mit der HAC Methode ermittelt. Sie sind konsistent in Bezug auf Autokorrelation und Heteroskedastizität.

* kennzeichnet Signifikanz zu einem Niveau von 10%, ** zu 5% und *** zu 1%. Die Hausman-Statistik entscheidet zwischen „Fixed Effects und Random Effects“ Modell zu einem Signifikanzniveau von 5%. FEM steht für „Fixed Effects“ Modell und REM für „Random Effects“ Modell. Die Spalte „F-Test Breusch-Pagan“ testet das Modell auf unterschiedliche Konstanten, im Fall des „Fixed Effects“ Modell mit einem einfachen F-Test und im Fall des „Random Effects“ mithilfe des Tests von Breusch-Pagan. Die Wendepunkte sind in € angegeben. Alle Schätzungen wurden in Gretl durchgeführt.

Tabelle 6.8: Die Schätzungen des Dienstleistungssektor für die Bruttowertschöpfung pro Erwerbstätigen als Regressor

Luftschadstoff	Parameter	HAC t-Statistik	Hausman Statistik	Modellspe- zifikation	F-Test Breusch-Pagan	Korrigiertes R^2	Wendepunkt(e)	Kurven- verlauf
Kohlendioxid	α	-2,220	2,8122	REM	197,553		103695,3	EKC
	β_1	2,276						
	β_2	-2,208						
Kohlenmonoxid	α	-2,052	0,974424	REM	251,149			Linear
	β_1	1,946						
Methan	α	-3,420	0,328237	REM	278,477			Linear
	β_1	1,236						
Schwefeldioxid	α	0,7824	4,10953	REM	131,595		89472,97	U-förmig
	β_1	-0,8459						
	β_2	0,8314						
Stickoxid	α	-3,250	1,60527	REM	230,992		90301,4	EKC
	β_1	3,151						
	β_2	-3,095						

Die präsentierten t-Statistiken der Koeffizienten wurden mit der HAC Methode ermittelt. Sie sind konsistent in Bezug auf Autokorrelation und Heteroskedastizität.

* kennzeichnet Signifikanz zu einem Niveau von 10%, ** zu 5% und *** zu 1%. Die Hausman-Statistik entscheidet zwischen „Fixed Effects und Random Effects“ Modell zu einem Signifikanzniveau von 5%. FEM steht für „Fixed Effects“ Modell und REM für „Random Effects“ Modell. Die Spalte „F-Test Breusch-Pagan“ testet das Modell auf unterschiedliche Konstanten, im Fall des „Fixed Effects“ Modell mit einem einfachen F-Test und im Fall des „Random Effects“ mithilfe des Tests von Breusch-Pagan. Die Wendepunkte sind in € angegeben. Alle Schätzungen wurden in Gretl durchgeführt.

Tabelle 6.9: Die Schätzungen des Dienstleistungssektors für den Produktionswert pro Erwerbstätigen als Regressor

Luftschadstoff	Parameter	HAC t-Statistik	Hausman Statistik	Modellspe- zifikation	F-Test Breusch-Pagan	Korrigiertes R^2	Wendepunkt(e)	Kurven- verlauf
Kohlendioxid	α	-76,9106***	0,545814	REM	287,384		817666,5	EKC
	β_1	12,0504***						
	β_2	-0,442567***	-2,776					
Kohlenmonoxid	α	-8,35832***	1,8999	REM	281,392			Linear
	β_1	0,581478***	3,845					
Methan	α	-15,7631***	0,0271423	REM	303,53			Linear
	β_1	0,915737***	4,604					
Schwefeldioxid	α	303,512***	12,31	FEM	334,793	0,9865	239401,8	U-förmig
	β_1	-49,8904***	-12,08					
	β_2	2,01400***	11,63					
Stickoxid	α	-20,4554***	-9,6279	REM	302,446			Linear
	β_1	1,58162***	10,81					

Die präsentierten t-Statistiken der Koeffizienten wurden mit der HAC Methode ermittelt. Sie sind konsistent in Bezug auf Autokorrelation und Heteroskedastizität.

* kennzeichnet Signifikanz zu einem Niveau von 10%, ** zu 5% und *** zu 1%. Die Hausman-Statistik entscheidet zwischen „Fixed Effects und Random Effects“ Modell zu einem Signifikanzniveau von 5%. FEM steht für „Fixed Effects“ Modell und REM für „Random Effects“ Modell. Die Spalte „F-Test Breusch-Pagan“ testet das Modell auf unterschiedliche Konstanten, im Fall des „Fixed Effects“ Modell mit einem einfachen F-Test und im Fall des „Random Effects“ mithilfe des Tests von Breusch-Pagan. Die Wendepunkte sind in € angegeben. Alle Schätzungen wurden in Gretl durchgeführt.

Methan und Kohlenmonoxid werden durch lineare Funktionen mit monoton wachsender Schadstoffemission modelliert.

Die drei anderen Luftschadstoffemissionen werden durch quadratische Funktionen dargestellt, wobei für Kohlendioxid und Stickoxid ein Beleg für die EKC Hypothese besteht. Die Beobachtungen der Bruttowertschöpfung pro Erwerbstätigen der Sektoren des Tertiärsektors liegen für diese Kurven unterhalb des Wendepunktes bzw. haben diesen gerade erreicht. Das bedeutet, dass sich die Beobachtungen auf dem Bereich der EKC Kurve befinden, wo eine Erhöhung der Bruttowertschöpfung pro Erwerbstätigen zu einer Erhöhung des Schadstoffausstoßes führt.

Schwefeldioxid folgt einem U-förmigen Verlauf. Die Schätzung ist zu einem Signifikanzniveau von 10% nicht signifikant. Die entsprechende „Fixed Effects“ Schätzung weist Signifikanz zu einem Niveau von 5% auf, die Hausman-Teststatistik nimmt aber die Nullhypothese eindeutig an.

Bei den Schätzungen mit dem Produktionswert pro Erwerbstätigen als unabhängige Variable (Tabelle 6.9) besteht ein Nachweis der EKC Kurve für Kohlendioxid. Die Beobachtungen des Produktionswerts pro Erwerbstätigen haben jedoch noch für keinen Sektor die Höhe des Wendepunktes erreicht.

Das Modell für Schwefeldioxid folgt einem U-förmigen Verlauf. Für Schwefeldioxid befinden sich die Beobachtungen des Produktionswerts pro Erwerbstätigen für drei der vier Sektoren am abnehmenden Ast der U-förmigen Kurve. Der vierte Sektor Flugverkehr hat den Wendepunkt bereits überschritten und befindet sich am zunehmenden Ast.

Die Luftschadstoffemissionen Kohlenmonoxid, Methan und Stickoxid werden durch lineare Funktionen mit steigender Schadstoffemission modelliert.

6.1.5 Ein Vergleich mit Italien

Die Studie von Mazzanti, Montini und Zoboli (2008) eignet sich für den Vergleich mit der NAMEA Österreich besonders, da dieselbe Fragestellung auf Basis der gleichen parametrischen Struktur untersucht wird. Die verfügbaren Daten von Österreich sind für die Jahre 1995-2007 und jene von Italien sind für 1990-2001. Ökonomisch betrachtet sind die Unterschiede der Volkswirtschaften Italien und Österreich sehr gering. Der geographische Unterschied des „reichen“ Nordens und „armen“ Südens Italiens spielt für den Vergleich auf sektoriellem Niveau nur eine untergeordnete Rolle.

Bei Betrachtung der Bruttowertschöpfung pro Erwerbstätigen als Regressor sind die Ergebnisse für alle produzierenden Sektoren für die Luftschadstoffemissionen Kohlenmonoxid, Methan und Schwefeldioxid gleich. Bei diesen wird die Emissionsentwicklung für CO und CH₄ durch eine N-förmige und für SO₂ durch eine U-förmige Kurve beschrieben. Die in Italien gefundene EKC Kurve für Kohlendioxid wird in Österreich durch ein lineares Modell ersetzt. Auch die Schätzung der Emission NO_x unterscheidet sich für die beiden Länder.

Die Schätzungen mit dem Produktionswert pro Erwerbstätigen als Regressor für alle produzierenden Sektoren ergeben die gleiche Schätzung für Stickoxid und Schwefeldioxid. Für NO_x trifft in beiden Ländern die EKC Hypothese zu und SO₂ wird als U-förmige Kurve modelliert. Der Beleg der EKC Kurve für Kohlendioxid in Österreich wird in Italien nicht gefunden. Die Schätzungen unterscheiden sich für Kohlenmonoxid und Stickoxid.

Die Entwicklung der Luftschadstoffemissionen für den gesamten produzierenden Bereich kann für die betrachteten Emissionen als ähnlich angesehen werden. Für Kohlendioxid wird in Italien die EKC Kurve für die Bruttowertschöpfung als Regressor gefunden, in Österreich hingegen für den Produktionswert.

Für die Aufteilung nach der Drei-Sektoren Hypothese ist ein Vergleich nur für die Bruttowertschöpfung pro Erwerbstätigen als erklärende Variable möglich, da die entsprechenden Daten für Italien nicht verfügbar sind. Aus dem Vergleich wird ersichtlich, dass sich die italienische Industrie inkl. Bauwirtschaft sehr ähnlich wie die österreichische verhält. Die Schätzungen der Modelle für Stickoxid und Kohlenmonoxid sind gleich. In der Landwirtschaft sieht das komplett anders aus, keine der Emissionen wird durch dasselbe Modell beschrieben. Diese Unterschiede können auf die in der Landwirtschaft enthaltenen Sektoren zurückgeführt werden. Da Italien vom Meer umgeben ist und Österreich nur Binnenschiffgewässer hat, gibt es in Italien wesentlich mehr Fischfang als Österreich. Österreich hingegen hat eine größere Forstwirtschaft, da es wesentlich mehr Wald besitzt. Auch für den Dienstleistungssektor sind die Ergebnisse sehr unterschiedlich. Die Schätzung gleicht sich nur für Methan, welches im Tertiärsektor kaum eine Rolle spielt.

Kapitel 7

Schlussbemerkungen

Diese Arbeit liefert neue Einblicke in die Analyse der Umwelt Kuznets Kurve für Luftschadstoffemissionen basierend auf sektoriellem Niveau. Der Datensatz, die NAMEA Österreich, umfasst 18 betrachtete Wirtschaftssektoren für den Beobachtungszeitraum 1995-2007. Besondere Aufmerksamkeit bei der Schätzung der EKC wird den statistischen Eigenschaften des Datensatzes geschenkt. Die grundlegende Fragestellung in diesem Zusammenhang ist, ob die verwendeten Zeitreihen stationär sind oder nicht.

Die Stationaritätsanalyse der Daten ist in der EKC Literatur kaum verbreitet und erst wenige Studien haben die Daten mit Hilfe von Einheitswurzeltests auf Stationarität untersucht. Für einen Paneldatensatz wie die NAMEA Österreich mit nur sehr wenigen Zeitperioden (13 Beobachtungen) ist die Untersuchung der Stationarität eine besondere Herausforderung, da die verfügbaren Unit Root Tests für Panels meist für Datensätze mit einer größeren Anzahl an Querschnittseinheiten und Zeitperioden konzeptioniert sind. Eine große Einschränkung der Einheitswurzeltests für Panels bildet die Annahme der Unabhängigkeit der Querschnittseinheiten untereinander. Erst die späteren Entwicklungen der Unit Root Tests erlauben Korrelationen zwischen den Querschnittseinheiten, wobei verschiedene Ansätze zur Modellierung der Abhängigkeiten verwendet werden. Die Einheitswurzeltests können daher zeitlich gesehen in die Einheitswurzeltests der ersten und zweiten Generation unterteilt werden.

Anders als erwartet zeigen die Ergebnisse der durchgeführten Einheitswurzeltests der zweiten Generation keine großen Unterschiede zu der ersten Generation. Die Testergebnisse liefern ein gemischtes Bild. Schon kleine Veränderungen in den An-

nahmen der Tests führen zu stark veränderten Testergebnissen. Im Weiteren ist die Ablehnung der Nullhypothese der Existenz einer Einheitswurzel abhängig von der Modellspezifikation. Für die Einheitswurzeltests mit einer Konstante werden die Nullhypothesen aller Variablen für die Hälfte der Tests verworfen und für die andere angenommen. Die Hinzunahme einer Trendkomponente in die Modellgleichung führt zu häufigerem Verwerfen der Nullhypothese. Die Stationarität der Daten kann nicht eindeutig geklärt werden. Es kann davon ausgegangen werden, dass die Daten eher der Modellspezifikation mit Konstante und linearem Trend entsprechen. Nach den Ergebnissen der Tests für diese Modellvariante sind die Daten stationär mit deterministischem Trend. Weitere Forschung ist notwendig um Gewissheit in diesem Punkt zu erlangen. Für einen Datensatz mit nur wenigen Zeitperioden, wie die NAMEA Österreich, werden neue Ansätze zur Klärung der Stationarität benötigt.

Im Weiteren bleiben die Auswirkungen der Verwendung von Transformationen von zum Teil nicht stationärer Zeitreihen für die Schätzungen ungeklärt. Die Transformationen müssen nicht dasselbe Verhalten wie die ursprüngliche Zeitreihe vorweisen und es kann daher zu Problemen kommen.

Im Anschluss wurde die EKC Hypothese für die fünf Luftschadstoffemissionen Kohlendioxid, Kohlenmonoxid, Methan, Schwefeldioxid und Stickoxid getestet. Wie erwartet, wurden Hinweise für die Existenz der EKC Kurve für einige Luftschadstoffemissionen gefunden. Die Modelle wurden einerseits mit dem Produktionswert dividiert durch die Erwerbstätigen und andererseits mit der Bruttowertschöpfung pro Erwerbstätigen als erklärende Variable geschätzt. Aus mikroökonomischer Sichtweise eignet sich der Produktionswert besser als Regressor.

Mit dem Produktionswert pro Erwerbstätigen als Regressor wird für alle produzierenden Sektoren für die Luftschadstoffemissionen Kohlendioxid, Kohlenmonoxid und Stickoxid ein Beleg für die Existenz der EKC Kurve gefunden. Kohlendioxid und Stickoxid werden durch eine inverse U-förmige Modellspezifikation, die ursprüngliche EKC, geschätzt. Kohlenmonoxid folgt einem N-förmigen Kurvenverlauf. Das bedeutet, dass zunächst wie bei der eigentlichen EKC der Schadstoffausstoß von CO mit steigendem Produktionswert pro Erwerbstätigen anwächst bis der erste Wendepunkt der Kurve überschritten wird, danach fällt der Ausstoß ab bis der zweite Wendepunkt erreicht wird. Bei diesem kommt es zu einer erneuten Koppelung des Schadstoffs und des Produktionswert und mit steigendem

Produktionswert pro Erwerbstätigen steigt die Emission von CO erneut an. Im Beobachtungszeitraum wurde der zweite Wendepunkt noch nicht überschritten. Das auch für das Treibhausgas Kohlendioxid ein Beleg für die EKC Kurve gefunden wurde, ist in der Literatur der EKC eine Seltenheit.

Methan wird für den betrachteten Zeitraum monoton steigend modelliert. Schwefeldioxid folgt einem U-förmigen Verlauf.

Beim Übergang zur Bruttowertschöpfung pro Erwerbstätigen als abhängige Variable bleibt die N-förmige Spezifikation bei Kohlenmonoxid und die U-förmige bei Schwefeldioxid gleich. Die Schätzungen von Kohlendioxid und Stickoxid werden durch lineare Modelle ersetzt, daher verschwinden die Nachweise der EKC. Methan wird durch eine N-förmige Kurve geschätzt, für welche die EKC Hypothese zutrifft.

Die Schadstoffemission Kohlendioxid entwickelt sich mit dem Produktionswert pro Erwerbstätigen als Regressor in allen Teilbereichen der Wirtschaft gleich wie für alle produzierenden Sektoren. Die Entwicklung des Schadstoffausstoßes von Stickoxid für alle produzierenden Sektoren wird durch den Primärsektor und den Sekundärsektor dominiert. Für den Tertiärsektor nimmt die Emission von NO_x linear zu. Die Entwicklung von Kohlenmonoxid ist für alle Teilbereiche verschieden von allen produzierenden Sektoren, nur im Landwirtschaftssektor wird ein Hinweis für die EKC in Form einer inversen U-förmigen Kurve gefunden. Die Entwicklung der Schadstoffemissionen des gesamten produzierenden Bereichs werden daher vor allem durch den Industriesektor und den Landwirtschaftssektor beeinflusst.

Für die Bruttowertschöpfung pro Erwerbstätigen als Prädiktor werden alle Emissionen im Landwirtschaftssektor durch lineare Modelle geschätzt. In diesem Fall ist der Unterschied zum Produktionswert pro Erwerbstätigen besonders deutlich.

Ein Vergleich mit einer Studie basierend auf der NAMEA Italien zeigt, dass es zwischen Österreich und Italien für den betrachteten Zeitraum bei der Entwicklung der Luftschadstoffemissionen für alle produzierenden Sektoren Gemeinsamkeiten gibt. Vor allem die Schadstoffentwicklung des Industriesektors gleicht sich in beiden Ländern.

Aus der EKC Analyse auf sektoriellem Niveau wird ersichtlich, dass makroökonomische Studien nicht im Stande sind die Heterogenitäten der einzelnen Sektoren aufzuzeigen. Das wird durch die unterschiedliche Entwicklung der Emissionen im

Primär-, Sekundär- und Tertiärsektor deutlich. Diese Arbeit zeigt, dass das Zutreffen der EKC Hypothese von der betrachteten Emission und den verwendeten Sektoren abhängig ist.

Obwohl diese Arbeit verstärkt auf die statistischen Kritikpunkte der EKC Literatur eingeht, ist weitere Forschung notwendig, um die statistischen Eigenschaften des Datensatzes eindeutig klären zu können und endgültig die Existenz der EKC Hypothese zu sichern.

Anhang A

Die Programmiercodes

Das Laden der Daten erfolgt in gretl entweder über das Konsolenfenster oder direkt mit der Befehlszeile:

```
open "C:\...\AlleSektoren-gruppenweise.gdt"
```

Die drei Punkte sollen den Pfad zu den Daten kennzeichnen.

Auf der beigelegten CD findet sich sowohl das ursprüngliche Excel File „AlleSektoren1995-2007.xls“ aus dem sie in jede Programmiersprache geladen werden können, sowie fünf Gretl Files. Das erste „AlleSektoren-gruppenweise.gdt“ wird für das Durchführen der Einheitswurzeltests benötigt. Es wird für jede Querschnittseinheit eine eigene Variable definiert. Die anderen sind für das Durchführen der „Fixed und Random Effects“ Modelle. „AlleSektoren.gdt“ beinhaltet den gesamten Datensatz in Panelstruktur. Die anderen drei sind für den Primärsektor „Landwirtschaft.gdt“, für den Sekundärsektor „Produktion.gdt“ und für den Tertiärsektor „Dienstleistung.gdt“.

A.1 Die Codes für die Einheitswurzeltests

Für das Durchführen der Einheitswurzeltests werden in den meisten Fällen, die verzögerten Variablen sowie die Differenzen benötigt. Das Skript „Daten modellieren.inp“ führt das für alle Variablen automatisch aus. Die folgenden Codes sind beispielhaft für Kohlendioxid (CO₂) angegeben.

```
# die verwendete Zeitreihe logarithmieren und durch die Erwerbstätigen dividieren:  
loop i=1..18 --quiet
```

```

    logC02_$i = log(C02_$i/EW_$i)
end loop

# die verzögerten Variablen der Zeitreihe definieren:
loop i=1..18 --quiet
loop j=1..12 --quiet
    genr logC02_$i_$j = logC02_$i(-$j)
end loop
end loop

# die Differenzen der Zeitreihe definieren:
loop i=1..18 --quiet
    genr d_logC02_$i = logC02_$i - logC02_$i_1
    loop j=1..11 ---quiet
        genr d_logC02_$i_$j = d_logC02_$i(-$j)
    end loop
end loop
end loop

```

Das Skript ist auf der beigelegten CD unter dem Namen „Daten modellieren“ abgespeichert.

Die folgenden Codes dienen zur Durchführung des jeweiligen Einheitswurzeltests für *CO2*. Sie geben jeweils die berechneten Teststatistiken zurück.

A.1.1 Der Test von Levin, Lin und Chu (2002)

Die Ausführung mit Konstante findet sich unter dem Namen „LLC-CO2-mw.inp“:

```

#Verzögerte Variablenordnung bestimmen:
loop i=1..18
    ols d_logC02_$i const logC02_$i_1 d_logC02_$i_1 d_logC02_$i_2 \
    d_logC02_$i_3 d_logC02_$i_4
    scalar t4_$i = $coeff(d_logC02_$i_4)/$stderr(d_logC02_$i_4)
    ols d_logC02_$i const logC02_$i_1 d_logC02_$i_1 d_logC02_$i_2 \
    d_logC02_$i_3
    scalar t3_$i = $coeff(d_logC02_$i_3)/$stderr(d_logC02_$i_3)
    ols d_logC02_$i const logC02_$i_1 d_logC02_$i_1 d_logC02_$i_2

```

```

    scalar t2_$i = $coeff(d_logCO2_$i_2)/$stderr(d_logCO2_$i_2)
    ols d_logCO2_$i const logCO2_$i_1 d_logCO2_$i_1
    scalar t1_$i = $coeff(d_logCO2_$i_1)/$stderr(d_logCO2_$i_1)
    adf -4 logCO2_$i --c --verbose --test-down # Zur Kontrolle
end loop

###1.Schritt:
#Hilfsregressionen durchführen:
loop i=1..18
if((t4_$i) < (-1.645))
ols d_logCO2_$i const logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2 \
d_logCO2_$i_3 d_logCO2_$i_4
g_$i = $sigma #Standardfehler des Modells abspeichern
#Hilfsregression 1:
ols d_logCO2_$i const d_logCO2_$i_1 d_logCO2_$i_2 d_logCO2_$i_3 \
d_logCO2_$i_4
genr e_$i= $uhat #Residuen des Modells abspeichern
#Hilfsregression 2:
ols logCO2_$i_1 const d_logCO2_$i_1 d_logCO2_$i_2 d_logCO2_$i_3 \
d_logCO2_$i_4
genr v1_$i= $uhat #Residuen des Modells abspeichern
#wird später für das Mittel der verzögerten Variablenordnung benötigt:
scalar mT_$i = 4

elif((t3_$i) < (-1.645))
ols d_logCO2_$i const logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2 \
d_logCO2_$i_3
g_$i = $sigma #Standardfehler des Modells abspeichern
#Hilfsregression 1:
ols d_logCO2_$i const d_logCO2_$i_1 d_logCO2_$i_2 d_logCO2_$i_3
genr e_$i= $uhat #Residuen des Modells abspeichern
#Hilfsregression 2:
ols logCO2_$i_1 const d_logCO2_$i_1 d_logCO2_$i_2 d_logCO2_$i_3
genr v1_$i= $uhat #Residuen des Modells abspeichern
scalar mT_$i = 3

```

```

elif((t2_$i) < (-1.645))
ols d_logCO2_$i const logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2
g_$i = $sigma #Standardfehler des Modells abspeichern
#Hilfsregression 1:
ols d_logCO2_$i const d_logCO2_$i_1 d_logCO2_$i_2
genr e_$i= $uhat #Residuen des Modells abspeichern
#Hilfsregression 2:
ols logCO2_$i_1 const d_logCO2_$i_1 d_logCO2_$i_2
genr v1_$i= $uhat #Residuen des Modells abspeichern
scalar mT_$i = 2

elif((t1_$i) < (-1.645))
ols d_logCO2_$i const logCO2_$i_1 d_logCO2_$i_1
g_$i = $sigma #Standardfehler des Modells abspeichern
#Hilfsregression 1:
ols d_logCO2_$i const d_logCO2_$i_1
genr e_$i= $uhat #Residuen des Modells abspeichern
#Hilfsregression 2:
ols logCO2_$i_1 const d_logCO2_$i_1
genr v1_$i= $uhat #Residuen des Modells abspeichern
scalar mT_$i = 1

else
ols d_logCO2_$i const logCO2_$i_1
g_$i = $sigma #Standardfehler des Modells abspeichern
#Hilfsregression 1:
ols d_logCO2_$i const
genr e_$i= $uhat #Residuen des Modells abspeichern
#Hilfsregression 2:
ols logCO2_$i_1 const
genr v1_$i= $uhat #Residuen des Modells abspeichern
scalar mT_$i = 0

end if
end loop

```

```

#Normalisieren der Residuen:
loop i=1..18
    genr eneu_$i = e_$i/g_$i
    genr v1neu_$i = v1_$i/g_$i
    print eneu_$i
    print v1neu_$i
end loop

###2.Schritt: Long Run Variance Ratio mit K=8 bestimmen:
#Daten mittelwert bereinigen:
loop i=1..18 --quiet
    genr m_logCO2_$i = d_logCO2_$i - mean(d_logCO2_$i)
end loop

loop i=1..18
#1.Summe der Long Run Variance Ratio (LRV)
    genr l2_$i = 1/12* sum(m_logCO2_$i * m_logCO2_$i)
    print l2_$i
#2.Summe der Long Run Variance Ratio:
    scalar l3_$i = 0
    loop j=1..8 --quiet #Schleife für K:
        genr l3_$i_$j = (1-$j/9) * (1/12* sum(m_logCO2_$i *d_logCO2_$i_$j))
        genr l3_$i = l3_$i + l3_$i_$j
    end loop
    genr l_$i = l2_$i + 2*l3_$i
    if(l_$i<0)
        l_$i = 0
    endif
    L_$i = sqrt(l_$i)
#i-tes Verhältnis von Standardabweichung zur LRV
    genr s_$i = L_$i/g_$i
end loop

#Mittel der Verhältnisse von Standardabweichung und LRV
scalar s=0
loop i=1..18

```

```

    scalar s= s + s_$i
end loop
scalar S = 1/18*s

###3.Schritt:
#Formel 1: Delta
scalar D1=0
scalar D2=0
loop i=1..18 --quiet
    genr d1_$i=v1neu_$i*eneu_$i # Zaehler
    scalar D1_$i=sum(d1_$i)
    scalar D1 = D1 + D1_$i
    genr d2_$i=v1neu_$i*v1neu_$i # Nenner
    scalar D2_$i=sum(d2_$i)
    scalar D2 = D2 + D2_$i
end loop
scalar D=D1/D2

#Formel 2: Sigma
scalar G1 = 0
loop i=1..18 --quiet
    genr g1_$i=sum((eneu_$i-D*v1neu_$i)*(eneu_$i-D*v1neu_$i))
    scalar G1 = G1 + g1_$i
end loop

scalar mt = 0 #Mittel der verzögerten Variablenordnung bestimmen
loop i=1..18 quiet
    mt = mt + mT_$i
end loop
scalar mT = floor(mt/18)
scalar G = G1/(18*(13-mT))

#Formel 3: STD(Delta)
scalar STD_D=sqrt(G)/sqrt(D2)

#Formel 4: t_delta

```

```

scalar t_delta = D/STD_D

#Formel 5: Die angepasste Teststatistik mit
scalar mu = -0.554
scalar sigma = 0.919
scalar t_delta_adj = (t_delta - 18*(13-mT-1)*S/G*STD_D*mu)/sigma
print t_delta_adj

```

Die Ausführung mit Konstante und linearem Trend findet sich unter „LLC-CO2-trend.inp“:

```

#Verzögerte Variablenordnung bestimmen:
loop i=1..18 --quiet
  ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2 \
  d_logCO2_$i_3 d_logCO2_$i_4
  scalar t4_$i = $coeff(d_logCO2_$i_4)/$stderr(d_logCO2_$i_4)
  ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2 \
  d_logCO2_$i_3
  scalar t3_$i = $coeff(d_logCO2_$i_3)/$stderr(d_logCO2_$i_3)
  ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2
  scalar t2_$i = $coeff(d_logCO2_$i_2)/$stderr(d_logCO2_$i_2)
  ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1
  scalar t1_$i = $coeff(d_logCO2_$i_1)/$stderr(d_logCO2_$i_1)
  adf -4 logCO2_$i --c --verbose --test-down # Zur Kontrolle
end loop

```

```

###1.Schritt:
#Hilfsregressionen durchführen:
loop i=1..18
  if((t4_$i) < (-1.645))
  ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2 \
  d_logCO2_$i_3 d_logCO2_$i_4
  g_$i = $sigma #Standardfehler des Modells abspeichern
#Hilfsregression 1:
ols d_logCO2_$i const time d_logCO2_$i_1 d_logCO2_$i_2 d_logCO2_$i_3 \
d_logCO2_$i_4

```

```

genr e_$i= $uhat #Residuen des Modells abspeichern
#Hilfsregression 2:
ols logCO2_$i_1 const time d_logCO2_$i_1 d_logCO2_$i_2 \
d_logCO2_$i_3 d_logCO2_$i_4
genr v1_$i= $uhat #Residuen des Modells abspeichern
#wird später für das Mittel der verzögerten Variablenordnung benötigt:
scalar mT_$i = 4

elif((t3_$i) < (-1.645))
ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2 \
d_logCO2_$i_3
g_$i = $sigma #Standardfehler des Modells abspeichern
#Hilfsregression 1:
ols d_logCO2_$i const time d_logCO2_$i_1 d_logCO2_$i_2 d_logCO2_$i_3
genr e_$i= $uhat #Residuen des Modells abspeichern
#Hilfsregression 2:
ols logCO2_$i_1 const time d_logCO2_$i_1 d_logCO2_$i_2 d_logCO2_$i_3
genr v1_$i= $uhat #Residuen des Modells abspeichern
scalar mT_$i = 3

elif((t2_$i) < (-1.645))
ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2
g_$i = $sigma #Standardfehler des Modells abspeichern
#Hilfsregression 1:
ols d_logCO2_$i const time d_logCO2_$i_1 d_logCO2_$i_2
genr e_$i= $uhat #Residuen des Modells abspeichern
#Hilfsregression 2:
ols logCO2_$i_1 const time d_logCO2_$i_1 d_logCO2_$i_2
genr v1_$i= $uhat #Residuen des Modells abspeichern
scalar mT_$i = 2

elif((t1_$i) < (-1.645))
ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1
g_$i = $sigma #Standardfehler des Modells abspeichern
#Hilfsregression 1:
ols d_logCO2_$i const time d_logCO2_$i_1

```

```

genr e_$i= $uhat #Residuen des Modells abspeichern
#Hilfsregression 2:
ols logCO2_$i_1 const time d_logCO2_$i_1
genr v1_$i= $uhat #Residuen des Modells abspeichern
scalar mT_$i = 1

else
ols d_logCO2_$i const time logCO2_$i_1
g_$i = $sigma #Standardfehler des Modells abspeichern
#Hilfsregression 1:
ols d_logCO2_$i const time
genr e_$i= $uhat #Residuen des Modells abspeichern
#Hilfsregression 2:
ols logCO2_$i_1 const time
genr v1_$i= $uhat #Residuen des Modells abspeichern
scalar mT_$i = 0

end if
end loop

#Normalisieren der Residuen:
loop i=1..18
    genr eneu_$i = e_$i/g_$i
    genr v1neu_$i = v1_$i/g_$i
    print eneu_$i
    print v1neu_$i
end loop

###2.Schritt: Long Run Variance Ratio mit K=8 bestimmen:
#Trend schätzen:
loop i=1..18 --quiet
    ols d_logCO2_$i const time
    genr b_$i = $coeff(time)
    genr a_$i = $coeff(const)
end loop

```

```

#Daten Trend bereinigen und neue verzögerte Variablen generieren:
loop i=1..18 --quiet
  genr d_CO2_tr_$i = d_logCO2_$i -a_$i -b_$i*time
  loop j=1..8 --quiet
    genr d_CO2_tr_$i_$j = d_CO2_tr_$i(-$j)
  end loop
end loop

loop i=1..18
#1.Summe der Long Run Variance Ratio (LRV)
  genr l2_$i = 1/12* sum(d_CO2_tr_$i * d_CO2_tr_$i)
  print l2_$i
#2.Summe der Long Run Variance Ratio:
  scalar l3_$i = 0
  loop j=1..8 --quiet #Schleife für K:
    genr l3_$i_$j = 2*(1-$j/9) * (1/12* sum(d_CO2_tr_$i *d_CO2_tr_$i_$j))
  genr l3_$i = l3_$i + l3_$i_$j
  end loop
  genr l_$i = l2_$i + l3_$i
  if(l_$i<0)
    l_$i = 0
  endif
  L_$i = sqrt(l_$i)
#i-tes Verhältnis von Standardabweichung zur LRV:
  genr s_$i = L_$i/g_$i
end loop

scalar s=0 #Mittel der Verhältnisse von Standardabweichung und LRV
loop i=1..18
  scalar s= s + s_$i
end loop
scalar S = 1/18*s

###3.Schritt:
#Formel 1: Delta
scalar D1=0

```

```

scalar D2=0
loop i=1..18 --quiet
    genr d1_$i=v1neu_$i*eneu_$i # Zaehler
    scalar D1_$i=sum(d1_$i)
    scalar D1 = D1 + D1_$i
    genr d2_$i=v1neu_$i*v1neu_$i # Nenner
    scalar D2_$i=sum(d2_$i)
    scalar D2 = D2 + D2_$i
end loop
scalar D=D1/D2

#Formel 2: Sigma
scalar G1 = 0
loop i=1..18 --quiet
    genr g1_$i=sum((eneu_$i-D*v1neu_$i)*(eneu_$i-D*v1neu_$i))
    scalar G1 = G1 + g1_$i
end loop

scalar mt = 0 #Mittel der verzögerten Variablenordnung bestimmen
loop i=1..18 --quiet
    mt = mt + mT_$i
end loop
scalar mT = floor(mt/18)
scalar G = G1/(18*(13-mT-1))

#Formel 3: STD(Delta)
scalar STD_D=sqrt(G)/sqrt(D2)

#Formel 4: t_delta
scalar t_delta = D/STD_D

#Formel 5: Die angepasste Teststatistik mit
scalar mu = -0.703
scalar sigma = 1.003
scalar t_delta_adj = (t_delta - 18*(13-mT-1)*S/G*STD_D*mu)/sigma
print t_delta_adj

```

A.1.2 Der Test von Im, Pesaran und Shin (2003)

Das Skript ist auf der CD unter dem Namen „IPS-CO2.inp“ abgespeichert.

```
#ADF Tests für die AR(1) Regressionen:

# t_bar tilda mit Konstante
scalar t_c=0
loop i=1..18 --quiet
    ols d_logCO2_$i const logCO2_$i_1
    scalar t_c_$i = $coeff(logCO2_$i_1)/$stderr(logCO2_$i_1)
    scalar t_c= t_c + t_c_$i
end loop
scalar t_c_bar = (sqrt(18)*(1/18*t_c + 1.504))/sqrt(1.069)

# t_bar tilda mit Konstante und Trend
scalar t_ct=0
loop i=1..18 --quiet
    ols d_logCO2_$i const time logCO2_$i_1
    scalar t_ct_$i = $coeff(logCO2_$i_1)/$stderr(logCO2_$i_1)
    scalar t_ct= t_ct + t_ct_$i
end loop
scalar t_ct_bar = (sqrt(18)*(1/18*t_ct + 1.504))/sqrt(1.069)

#####
#ADF Tests für die AR(p) Regressionen:

#Für die Anpassungen der individuellen p_i:
#Konstante:
loop i=1..18 --quiet
    ols d_logCO2_$i const logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2\
    d_logCO2_$i_3 d_logCO2_$i_4
    scalar t4_c_$i = $coeff(d_logCO2_$i_4)/$stderr(d_logCO2_$i_4)
    ols d_logCO2_$i const logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2\
    d_logCO2_$i_3
    scalar t3_c_$i = $coeff(d_logCO2_$i_3)/$stderr(d_logCO2_$i_3)
    ols d_logCO2_$i const logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2
```

```

    scalar t2_c_$i = $coeff(d_logC02_$i_2)/$stderr(d_logC02_$i_2)
    ols d_logC02_$i const logC02_$i_1 d_logC02_$i_1
    scalar t1_c_$i = $coeff(d_logC02_$i_1)/$stderr(d_logC02_$i_1)
end loop
loop i=1..18
    if((t4_c_$i) < (-1.645))
        m_c_$i = -1.171
        var_c_$i = 2.080
        ols d_logC02_$i const logC02_$i_1 d_logC02_$i_1 d_logC02_$i_2\
d_logC02_$i_3 d_logC02_$i_4
        scalar tp_c_$i = $coeff(logC02_$i_1)/$stderr(logC02_$i_1)

    elif((t3_c_$i) < (-1.645))
        m_c_$i = -1.306
        var_c_$i = 1.759
        ols d_logC02_$i const logC02_$i_1 d_logC02_$i_1 d_logC02_$i_2\
d_logC02_$i_3
        scalar tp_c_$i = $coeff(logC02_$i_1)/$stderr(logC02_$i_1)

    elif((t2_c_$i) < (-1.645))
        m_c_$i = -1.319
        var_c_$i = 1.421
        ols d_logC02_$i const logC02_$i_1 d_logC02_$i_1 d_logC02_$i_2
        scalar tp_c_$i = $coeff(logC02_$i_1)/$stderr(logC02_$i_1)

    elif((t1_c_$i) < (-1.645))
        m_c_$i = 1.488
        var_c_$i = 1.255
        ols d_logC02_$i const logC02_$i_1 d_logC02_$i_1
        scalar tp_c_$i = $coeff(logC02_$i_1)/$stderr(logC02_$i_1)

else
    m_c_$i = -1.504
    var_c_$i = 1.069
    ols d_logC02_$i const logC02_$i_1
    scalar tp_c_$i = $coeff(logC02_$i_1)/$stderr(logC02_$i_1)

```

```

endif
end loop

#Konstante und Trend:
loop i=1..18 --quiet
  ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2\
  d_logCO2_$i_3 d_logCO2_$i_4
  scalar t4_ct_$i = $coeff(d_logCO2_$i_4)/$stderr(d_logCO2_$i_4)
  ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2\
  d_logCO2_$i_3
  scalar t3_ct_$i = $coeff(d_logCO2_$i_3)/$stderr(d_logCO2_$i_3)
  ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2
  scalar t2_ct_$i = $coeff(d_logCO2_$i_2)/$stderr(d_logCO2_$i_2)
  ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1
  scalar t1_ct_$i = $coeff(d_logCO2_$i_1)/$stderr(d_logCO2_$i_1)
end loop
loop i=1..18
  if((t4_ct_$i) < -(1.645))
    m_ct_$i = -1.75
    var_ct_$i = 3.947
    ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2\
    d_logCO2_$i_3 d_logCO2_$i_4
    scalar tp_ct_$i = $coeff(logCO2_$i_1)/$stderr(logCO2_$i_1)

  elif((t3_ct_$i) < -(1.645))
    m_ct_$i = -1.922
    var_ct_$i = 2.482
    ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2\
    d_logCO2_$i_3
    scalar tp_ct_$i = $coeff(logCO2_$i_1)/$stderr(logCO2_$i_1)

  elif((t2_ct_$i) < -(1.645))
    m_ct_$i = -1.914
    var_ct_$i = 1.627
    ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1 d_logCO2_$i_2
    scalar tp_ct_$i = $coeff(logCO2_$i_1)/$stderr(logCO2_$i_1)

```

```

elif((t1_ct_$i) < -(1.645))
    m_ct_$i = -2.173
    var_ct_$i =1.453
    ols d_logCO2_$i const time logCO2_$i_1 d_logCO2_$i_1
    scalar tp_ct_$i = $coeff(logCO2_$i_1)/$stderr(logCO2_$i_1)

else
    m_ct_$i = -2.166
    var_ct_$i = 1.132
    ols d_logCO2_$i const time logCO2_$i_1
    scalar tp_ct_$i = $coeff(logCO2_$i_1)/$stderr(logCO2_$i_1)
endif
end loop

# t_bar tilda mit Konstante
scalar tp_c=0
scalar m_c = 0
scalar var_c = 0
loop i=1..18 --quiet
    scalar tp_c= tp_c + tp_c_$i
    scalar m_c = m_c + m_c_$i
    scalar var_c = var_c + var_c_$i
end loop
scalar E_t_c = 1/18*(m_c)
scalar Var_t_c = 1/18*(var_c)
scalar tp_c_bar = (sqrt(18)*(1/18*tp_c + E_t_c))/sqrt(Var_t_c)

# t_bar tilda mit Konstante und Trend
scalar tp_ct=0
scalar m_ct = 0
scalar var_ct = 0
loop i=1..18 --quiet
    scalar tp_ct= tp_ct + tp_ct_$i
    scalar m_ct = m_ct + m_ct_$i
    scalar var_ct = var_ct + var_ct_$i

```

```

end loop
scalar E_t_ct = 1/18*(m_ct)
scalar Var_t_ct = 1/18*(var_ct)
scalar tp_ct_bar = (sqrt(18)*(1/18*tp_ct + E_t_ct))/sqrt(Var_t_ct)

#Alle Teststatistiken:
#AR(1)
print t_c_bar #Konstante
print t_ct_bar
#AR(pi)
print tp_c_bar #konstante und Trend
print tp_ct_bar

```

A.1.3 Die Fisher Tests

Das Skript ist auf der CD unter dem Namen „Fisher-CO2.inp“ abgespeichert.

```

#relevante verzögerte Variablen bestimmen
#und p-Wert des entsprechenden ADF Tests abspeichern:
loop i=1..18
adf -4 logCO2_$i --c --verbose
scalar p_c_$i= $pvalue
adf -4 logCO2_$i --ct --verbose
scalar p_ct_$i= $pvalue
end loop

#####
#p-Test mit Konstante
scalar logp_c=0
loop i=1..18 --quiet
    scalar logp_c= logp_c + log(p_c_$i)
end loop
scalar l_c= -2*logp_c
print l_c

#p-Test mit Konstante und Trend
scalar logp_ct=0

```

```

loop i=1..18 --quiet
    scalar logp_ct= logp_ct + log(p_ct_$i)
end loop
scalar l_ct= -2*logp_ct
print l_ct

#####
#z-Test mit Konstante
scalar logz_c=0
loop i=1..18 --quiet
    scalar logz_c= logz_c + invcdf(N,(p_c_$i))
end loop
scalar z_c= 1/sqrt(13)*logz_c
print z_c

#z-Test mit Konstante und Trend
scalar logz_ct=0
loop i=1..18 --quiet
    scalar logz_ct= logz_ct + invcdf(N,(p_ct_$i))
end loop
scalar z_ct= 1/sqrt(13)*logz_ct
print z_ct

```

A.1.4 Der Test von Pesaran (2007)

Der Code ist unter „Pesaran-CO2.inp“ abgespeichert.

```

#Mittel von x_0 bestimmen:
m_C02 = 0
loop j=1..18 --quiet
    m_C02 = m_C02 + logC02_$j[1]
end loop
M_C02 = m_C02/18

#Mittel von x_0 von den Daten abziehen:
loop i=1..18 --quiet
C02_$i =logC02_$i -M_C02

```

```

end loop
#Verzögerte Variable und Differenz bestimmen:
loop i=1..18 --quiet
    CO2_$i_1= CO2_$i(-1)
    d_CO2_$i = CO2_$i - CO2_$i_1
    CO2_$i_1[1]=0
    d_CO2_$i[1]=0
end loop

#Gruppenmittel von x_t_1 und Delta x_t bestimmen:
series d_mt_CO2 = 0
series mt_CO2_1 = 0
loop i=2..13 --quiet
    loop j=1..18 --quiet
        genr d_mt_CO2[$i] = d_mt_CO2[$i] + d_CO2_$j[$i] #Mittel von Delta x_t
        genr mt_CO2_1[$i] = mt_CO2_1[$i] + CO2_$j_1[$i] #Mittel von x_t-1
    end loop
end loop
d_Mt_CO2 = d_mt_CO2/18
Mt_CO2_1 = mt_CO2_1/18

#t-Statistik für jede Gruppe bestimmen:
loop i=1..18 #für Konstante:
    ols d_CO2_$i const CO2_$i_1 Mt_CO2_1 d_Mt_CO2
    scalar t_c_$i = $coeff(CO2_$i_1)/$stderr(CO2_$i_1)
end loop

loop i=1..18 #für Konstante und linearen Trend:
    ols d_CO2_$i const time CO2_$i_1 Mt_CO2_1 d_Mt_CO2
    scalar t_ct_$i = $coeff(CO2_$i_1)/$stderr(CO2_$i_1)
end loop

#CIPS Statistik für Konstante:
C_c = 0
loop i=1..18 --quiet

```

```

        C_c = C_c + t_c_$i
    end loop

    scalar CIPS_c = C_c/18

    #CIPS* Statistik für Konstante:
    loop i=1..18
    if(t_c_$i<(-6.19))
    t_c_$i =-6.19
    endif
    if (t_c_$i>2.61)
    t_c_$i = 2.61
    end if
    endloop

    D_c = 0
    loop i=1..18 --quiet
        D_c = D_c + t_c_$i
    end loop
    scalar DIPS_c = D_c/18

    #CIPS Statistik für Konstante und linearen Trend:
    C_ct = 0
    loop i=1..18 --quiet
        C_ct = C_ct + t_ct_$i
    end loop

    scalar CIPS_ct = C_ct/18

    #CIPS* Statistik für Konstante und linearen Trend:
    loop i=1..18
    if(t_ct_$i<(-6.19))
    t_ct_$i =-6.19
    endif
    if (t_ct_$i>2.61)

```

```

t_ct_$i = 2.61
end if
endloop

D_ct = 0
loop i=1..18 --quiet
    D_ct = D_ct + t_ct_$i
end loop
scalar DIPS_ct = D_ct/18

#Alle Teststatistiken ausgeben:
print CIPS_c
print DIPS_c
print CIPS_ct
print DIPS_ct

```

A.1.5 Der Test von Choi (2002)

Die Testprozedur für das Modell mit Konstante ist unter „Choi-CO2-mw.inp“ auf der beigelegten CD zu finden.

```

#Variablen für die GLS Schätzung von alpha_i0 definieren:
loop i=1..18 --quiet
    series CO2_$i_m = 0
    CO2_$i_m[1] = logCO2_$i[1]
    loop j=2..13 --quiet
        CO2_$i_m[$j] = logCO2_$i[$j] -(1-7/13)*logCO2_$i[$j-1]
    end loop
end loop
series c_1 = 1
loop j= 2..13 --quiet
    c_1[$j] = 1-(1-7/13)
end loop

#Schätzung durchführen:
loop i=1..18
    ols CO2_$i_m c_1

```

```

        a0_$i = $coeff(c_1)
    end loop

#Mittelwert bereinigte Reihe generieren:
loop i=1..18 --quiet
    x_$i = logCO2_$i - a0_$i
end loop
x=0
loop i=1..18 --quiet
    x = x + sum(x_$i)
end loop

loop i=1..18 --quiet
    z_$i = logCO2_$i - a0_$i - 1/18*x
end loop

#ADF-Tests durchführen:
loop i=1..18
    adf -3 z_$i --nc --verbose
    scalar p_c_$i= $pvalue
end loop

#####
#z-Test mit Konstante:
scalar logz_c=0
loop i=1..18 --quiet
    scalar logz_c= logz_c + invcdf(N,(p_c_$i))
end loop
print logz_c
scalar z_c= 1/sqrt(18)*logz_c
print z_c

#Pm-Test mit Konstante:
scalar logpm_c=0
loop i=1..18 --quiet
    scalar logpm_c= logpm_c + log(p_c_$i) + 1

```

```

end loop
scalar pm_c= -1/sqrt(18)*logpm_c
print pm_c

```

Die Testprozedur für das Modell mit Konstante und linearen Trend ist unter „Choi-CO2-trend.inp“ auf der beigelegten CD zu finden.

#Variablen für die GLS Schätzung von α_{i0} und α_{i1} definieren:

```

loop i=1..18 --quiet
    series C02_$i_t = 0
    C02_$i_t[1] = logC02_$i[1]
    loop j=2..13 --quiet
        C02_$i_t[$j] = logC02_$i[$j] - (1-13.5/13)*logC02_$i[$j-1]
    end loop
end loop
series c_2 = 1
loop j= 2..13 --quiet
    c_2[$j] = 1-(1-13.5/13)
end loop
series c_3 = 1
loop j= 2..13
    c_3[$j] = 1-((-13.5)*($j-1))/13
end loop

```

#Schätzung durchführen:

```

loop i=1..18
    ols C02_$i_t c_2 c_3
    genr a0_$i = $coeff(c_2)
    genr a1_$i = $coeff(c_3)
end loop

```

#Trend bereinigte Reihe generieren:

```

loop i=1..18 --quiet
    y_$i = logC02_$i - a0_$i - a1_$i*time
end loop
y=0
loop i=1..18 --quiet

```

```

        y = y + sum(y_$i)
    end loop

    loop i=1..18 --quiet
        z_$i = logCO2_$i - a0_$i - a1_$i*time - 1/18*y
    end loop

###ADF-Tests
loop i=1..18
adf -3 z_$i --nc --verbose
scalar p_ct_$i= $pvalue
end loop

#####
#z-Test mit Konstante und Trend:
scalar logz_ct=0
loop i=1..18 --quiet
    scalar logz_ct= logz_ct + invcdf(N, (p_ct_$i))
end loop
scalar z_ct= 1/sqrt(18)*logz_ct
print z_ct

#pm-Test mit Konstante und Trend:
scalar logpm_ct=0
loop i=1..18 --quiet
    scalar logpm_ct= logpm_ct + log(p_ct_$i) + 1
end loop
scalar pm_ct= -1/sqrt(18)*logpm_ct
print pm_ct

```

A.1.6 Die Informationskriterien

Das entsprechende Skript findet sich unter „Info-CO2.inp“ auf der beigelegten CD.

```

#Für die Differenzen:
#Die Daten richtig abspeichern:
loop i=1..18 --quiet

```

```

    x_$i = d_logCO2_$i
end loop

#Die Daten als Matrix abspeichern:
matrix X = {x_1, x_2, x_3, x_4, x_5, x_6, x_7,\
    x_8, x_9, x_10, x_11, x_12, x_13, x_14, x_15, x_16, x_17, x_18}

#Die Eigenwerte und Eigenvektoren von XX' bestimmen:
matrix M = (X*transp(X))
matrix D = {}#dient zum Abspeichern der Eigenvektoren
eigensym(M, &D)

#f und lambda definieren, wobei mit k_max=5 gemeinsamen Faktoren
#gestartet wird:
loop k=1..5 --quiet
    matrix F_$k = sqrt(12)*D[ ,1:$k]
    matrix L_$k = transp(F_$k)*X/12

    #Residuen für k=$i bestimmen:
    matrix Z_$k = X - F_$k*L_$k
    matrix W_$k = transp(Z_$k)*Z_$k #Residuen gruppenweise multiplizieren
    w_$k = tr(W_$k)# addiert e_i*e_i
    Var_$k = w_$k/(18*12) #Mittel der Residuen
end loop

#Informationskriterien durchführen:
loop k=1..5
    BIC_$k = Var_$k + $k * Var_5 * (((18+12-$k)*ln(18*12))/(18*12))
    AIC_$k = Var_$k + $k * Var_5 * (2*(18+12-$k)/(18*12))
    PC1_$k = Var_$k + $k * Var_5 * ((12+18)/(12*18)) \
        * ln((12*18)/(12+18))
    PC2_$k = Var_$k + $k * Var_5 * ((12+18)/(12*18)) * ln(12)
    PC3_$k = Var_$k + $k * Var_5 * (ln(12)/(12))
end loop

#Funktion um das Minimum des Informationskriteriums zu bestimmen:

```

```

function criterion \
(scalar x_5, scalar x_4, scalar x_3, scalar x_2, scalar x_1)
if(x_4<x_5)
    scalar crit = 4
    scalar x = x_4
else
    scalar crit = 5
    scalar x = x_5
endif
if(x_3<x)
    scalar crit = 3
    scalar x = x_3
endif
if(x_2<x)
    scalar crit = 2
    scalar x = x_2
endif
if(x_1<x)
    scalar crit = 1
endif
    return scalar crit
end function

#Minimum der Informationskriterien für die Differenzen bestimmen:
BIC = criterion(BIC_5, BIC_4, BIC_3, BIC_2, BIC_1)
print BIC
AIC = criterion(AIC_5, AIC_4, AIC_3, AIC_2, AIC_1)
print AIC
PC1 = criterion(PC1_5, PC1_4, PC1_3, PC1_2, PC1_1)
print PC1
PC2 = criterion(PC2_5, PC2_4, PC2_3, PC2_2, PC2_1)
print PC2
PC3 = criterion(PC3_5, PC3_4, PC3_3, PC3_2, PC3_1)
print PC3

#####

```

```

#Für die Residuen:
#Zunächst muss der gepoolte Schätzer bestimmt werden:
loop i=1..18 --quiet
    y_$i = logCO2_$i
    y_$i_1 = logCO2_$i_1
    y_$i_1[1]=0
end loop
matrix Y = {y_1, y_2, y_3, y_4, y_5, y_6, y_7, y_8,\
    y_9, y_10, y_11, y_12, y_13, y_14, y_15, y_16, y_17, y_18}
matrix Y_1 = {y_1_1, y_2_1, y_3_1, y_4_1, y_5_1, y_6_1,\
    y_7_1, y_8_1, y_9_1, y_10_1, y_11_1, y_12_1, y_13_1,\
    y_14_1, y_15_1, y_16_1, y_17_1, y_18_1}
matrix A = transp(Y_1)*Y
matrix B = transp(Y_1)*Y_1
rho_pool = tr(A)/tr(B)

#Die Residuen bestimmen:
loop i=1..18 --quiet
    r_$i = y_$i - rho_pool*y_$i_1
end loop

#Die Residuen als Matrix abspeichern:
matrix R = {r_1, r_2, r_3, r_4, r_5, r_6, r_7, r_8,\
    r_9, r_10, r_11, r_12, r_13, r_14, r_15, r_16, r_17, r_18}

#Die Eigenwerte und Eigenvektoren von RR' bestimmen:
matrix N = (R*transp(R))
matrix P = {}#dient zum Abspeichern der Eigenvektoren
eigensym(N, &P)

#f und lambda definieren, wobei mit k_max=5 gemeinsamen Faktoren \
#gestartet wird:
loop k=1..5 --quiet
    matrix f_$k = sqrt(13)*P[ ,1:$k]
    matrix l_$k = transp(f_$k)*Y/13

```

```

#Residuen für k=$i bestimmen:
matrix U_$k = R - f_$k*l_$k
matrix V_$k = transp(U_$k)*U_$k #Residuen gruppenweise multiplizieren
v_$k = tr(V_$k)# addiert e_i*e_i
var_$k = v_$k/(18*13) #Mittel der Residuen
end loop

loop k=1..5
  R_BIC_$k = var_$k + $k * var_5 * (((18+12-$k)*ln(18*12))/(18*12))
  R_AIC_$k = var_$k + $k * var_5 * (2*(18+12-$k)/(18*12))
  R_PC1_$k = var_$k + $k * var_5 * ((12+18)/(12*18)) \
  * ln((12*18)/(12+18))
  R_PC2_$k = var_$k + $k * var_5 * ((12+18)/(12*18)) * ln(12)
  R_PC3_$k = var_$k + $k * var_5 * (ln(12)/(12))
end loop

#Minimum der Informationskriterien für die Residuen bestimmen:
R_BIC = criterion(R_BIC_5, R_BIC_4, R_BIC_3, R_BIC_2, R_BIC_1)
print R_BIC
R_AIC = criterion(R_AIC_5, R_AIC_4, R_AIC_3, R_AIC_2, R_AIC_1)
print R_AIC
R_PC1 = criterion(R_PC1_5, R_PC1_4, R_PC1_3, R_PC1_2, R_PC1_1)
print R_PC1
R_PC2 = criterion(R_PC2_5, R_PC2_4, R_PC2_3, R_PC2_2, R_PC2_1)
print R_PC2
R_PC3 = criterion(R_PC3_5, R_PC3_4, R_PC3_3, R_PC3_2, R_PC3_1)
print R_PC3

#####
#Für die Niveaus:

#Die Daten als Matrix abspeichern:
matrix C02 = {logC02_1, logC02_2, logC02_3, logC02_4, logC02_5, \
logC02_6, logC02_7, logC02_8, logC02_9, logC02_10, logC02_11, \
logC02_12, logC02_13, logC02_14, logC02_15, logC02_16,logC02_17, \
logC02_18}

```

```

#Die Eigenwerte und Eigenvektoren von XX' bestimmen:
matrix A = (CO2*transp(CO2))
matrix B = {}#dient zum Abspeichern der Eigenvektoren
eigensym(A, &B)

#f und lambda definieren, wobei mit k_max=5 gemeinsamen Faktoren \
#gestartet wird:
loop k=1..5 --quiet
  matrix Fl_$k = sqrt(12)*B[ ,1:$k]
  matrix Ll_$k = transp(Fl_$k)*CO2/12

  #Residuen für k=$i bestimmen:
  matrix Zl_$k = CO2 - Fl_$k*Ll_$k
  #Residuen gruppenweise multiplizieren:
  matrix Wl_$k = transp(Zl_$k)*Zl_$k
  wl_$k = tr(Wl_$k)# addiert e_i*e_i
  Varl_$k = wl_$k/(18*12) #Mittel der Residuen
end loop

#Informationskriterien durchführen:
a = 13/(4*ln(ln(13))) #alpha definieren
loop k=1..5
  L_BIC_$k = Varl_$k + $k * Varl_5 * a * (((18+12-$k)*ln(18*12))/(18*12))
  L_PC1_$k = Varl_$k + $k * Varl_5 * a * ((12+18)/(12*18)) \
  * ln((12*18)/(12+18))
  L_PC2_$k = Varl_$k + $k * Varl_5 * a * ((12+18)/(12*18)) * ln(12)
end loop

#Minimum der Informationskriterien für die Residuen bestimmen:
L_BIC = criterion(L_BIC_5, L_BIC_4, L_BIC_3, L_BIC_2, L_BIC_1)
print L_BIC
L_PC1 = criterion(L_PC1_5, L_PC1_4, L_PC1_3, L_PC1_2, L_PC1_1)
print L_PC1
L_PC2 = criterion(L_PC2_5, L_PC2_4, L_PC2_3, L_PC2_2, L_PC2_1)
print L_PC2

```

A.1.7 Der Test von Bai und Ng (2004)

Die Testprozedur für das Modell mit Konstante ist unter „BN-CO2-mw.inp“ auf der beigelegten CD zu finden.

```
#Hauptkomponentenanalyse:
loop i=1..18
    x_$i = d_logCO2_$i
end loop
matrix X = {x_1, x_2, x_3, x_4, x_5, x_6, x_7, \
    x_8, x_9, x_10, x_11, x_12, x_13, x_14, \
    x_15, x_16, x_17, x_18}

matrix M = (X*transp(X))
matrix D = {}

eigensym(M, &D)

#Die gemeinsamen Faktoren und Faktorenladungen
#definieren mit k=1 (von Informationskriterien):
matrix F = D[,1]*sqrt(12)
matrix L = transp(F)*X/12

#Die Residuen bestimmen:
Z = X - F*L

#Die Daten in Vektoren umschreiben:
loop i=1..18 --quiet
    series z_$i = 0
    z_$i= Z[, $i]
end loop

#Überdifferenzierung vermeiden:
loop i=1..18
    series e_$i = 0
    e_$i[1] = z_$i[1]
loop j=2..12
```

```

    e_{$i}[$j] = z_{$i}[$j] + e_{$i}[$j-1]
end loop
end loop
series f = 0
f[2] = F[1,1]
loop j=3..13
    f[$j] = F[$j-1,1] + f[$j-1]
end loop

###Der Test für die idiosynkratische Komponente:
#Individuelle ADF Tests:
loop i=1..18 --quiet
    adf -4 e_{$i} --nc
p_{$i} = $pvalue
end loop

#Die gepoolte Teststatistik:
P=0
loop i=1..18 --quiet
    P = P + log(p_{$i})
end loop
Pc = (-2*P-2*18)/sqrt(4*18)

###Test für die gemeinsamen Faktoren:
#k=1:
adf -4 f --c --verbose

Die Testprozedur für das Modell mit Konstante und linearen Trend ist unter „BN-
CO2-trend.inp“ auf der beigelegten CD zu finden.

#Hauptkomponentenanalyse:
loop i=1..18 --quiet
    x_{$i} = d_logCO2_{$i} - mean(d_logCO2_{$i})
end loop
matrix X = {x_1, x_2, x_3, x_4, x_5, x_6, x_7, \
    x_8, x_9, x_10, x_11, x_12, x_13, x_14, \
    x_15, x_16, x_17, x_18}

```

```

matrix M = (X*transp(X))
matrix D = {}

eigensym(M, &D)

#Die gemeinsamen Faktoren und Faktorenladungen
#definieren mit k=1 (von Informationskriterien):
matrix F = D[ ,2]*sqrt(12)
matrix L = transp(F)*X/12

#Die Residuen bestimmen:
Z = X - F*L

#Die Daten in Vektoren umschreiben:
loop i=1..18 --quiet
    series z_$i = 0
    z_$i= Z[, $i]
end loop

#Überdifferenzierung vermeiden:
loop i=1..18 --quiet
    series e_$i = 0
e_$i[1] = z_$i[1]
loop j=2..12 --quiet
    e_$i[$j] = z_$i[$j] + e_$i[$j-1]
end loop
end loop
series f = 0
f[2] = F[1,1]
loop j=3..13 --quiet
    f[$j] = F[$j-1,1] + f[$j-1]
end loop

###Der Test für die idiosynkratische Komponente:
#Individuelle ADF Tests:

```

```

loop i=1..18 --quiet
    adf -4 e_$$i --nc
p_$$i = $pvalue
end loop

#Die gepoolte Teststatistik:
P=0
loop i=1..18 --quiet
    P = P + log(p_$$i)
end loop
Pc = (-2*P-(2*18))/sqrt(4*18)

```

```

###Der Test für die gemeinsamen Faktoren:
#k=1:
adf -4 f --ct --verbose

```

A.1.8 Der Test von Breitung und Das (2005)

Die Testprozedur für das Modell mit Konstante ist unter „BD-CO2-mw.inp“ auf der beigelegten CD zu finden.

```

#Mittelwert bereinigen:
loop i=1..18 --quiet
    CO2_$$i_m = logCO2_$$i - logCO2_$$i[1]
end loop

#Verzögerte Variablen definieren:
loop i=1..18 --quiet
    genr CO2_$$i_m_1 = CO2_$$i_m(-1)
end loop

#Pre-Whitening:
#Verzögerte Variablenordnung bestimmen:
loop i=1..18
    ols d_logCO2_$$i CO2_$$i_m_1 d_logCO2_$$i_1 d_logCO2_$$i_2 d_logCO2_$$i_3
    scalar t3_$$i = $coeff(d_logCO2_$$i_3)/$stderr(d_logCO2_$$i_3)
    ols d_logCO2_$$i CO2_$$i_m_1 d_logCO2_$$i_1 d_logCO2_$$i_2

```

```

        scalar t2_$i = $coeff(d_logC02_$i_2)/$stderr(d_logC02_$i_2)
        ols d_logC02_$i C02_$i_m_1 d_logC02_$i_1
        scalar t1_$i = $coeff(d_logC02_$i_1)/$stderr(d_logC02_$i_1)
    end loop

#Schätzung der verzögerten Variablenkoeffizienten:
loop i=1..18
    if((t3_$i) < (-1.645))
    ols d_logC02_$i C02_$i_m_1 d_logC02_$i_1 d_logC02_$i_2 d_logC02_$i_3
    genr u_$i=$uhat
    genr a1_$i = $coeff(d_logC02_$i_1)
    genr a2_$i = $coeff(d_logC02_$i_2)
    genr a3_$i = $coeff(d_logC02_$i_3)
    genr y_$i = C02_$i_m - a1_$i*d_logC02_$i_1 - a2_$i*d_logC02_$i_2 \
    - a3_$i*d_logC02_$i_3
    loop j=1..4 --quiet
        y_$i[$j] = 0
        u_$i[$j] = 0
    end loop

    elif((t2_$i) < (-1.645))
    ols d_logC02_$i C02_$i_m_1 d_logC02_$i_1 d_logC02_$i_2
    genr u_$i=$uhat
    genr a1_$i = $coeff(d_logC02_$i_1)
    genr a2_$i = $coeff(d_logC02_$i_2)
    genr y_$i = C02_$i_m - a1_$i*d_logC02_$i_1 - a2_$i*d_logC02_$i_2
    loop j=1..3 --quiet
        y_$i[$j] = 0
        u_$i[$j] = 0
    end loop

    elif((t1_$i) < (-1.645))
    ols d_logC02_$i C02_$i_m_1 d_logC02_$i_1
    genr u_$i=$uhat
    genr a1_$i = $coeff(d_logC02_$i_1)
    genr y_$i = C02_$i_m - a1_$i*d_logC02_$i_1

```

```

loop j=1..2 --quiet
    y_$(j) = 0
    u_$(j) = 0
end loop

    else
ols d_logCO2_$(i) CO2_$(i)_m_1
genr u_$(i)=$uhat
genr y_$(i) = CO2_$(i)_m
endif

genr y_$(i)_1 = y_$(i)(-1)
genr d_y_$(i) = y_$(i) - y_$(i)_1
y_$(i)_1[1]=0
d_y_$(i)[1]=0
endloop

#Daten als Matrizen abspeichern:
matrix Y_1 = {y_1_1, y_2_1, y_3_1, y_4_1, y_5_1, y_6_1, y_7_1, \
y_8_1,y_9_1, y_10_1, y_11_1, y_12_1, y_13_1, y_14_1, y_15_1, \
y_16_1, y_17_1, y_18_1}
matrix d_Y = {d_y_1, d_y_2, d_y_3, d_y_4, d_y_5, d_y_6, d_y_7, \
d_y_8, d_y_9, d_y_10, d_y_11, d_y_12, d_y_13, d_y_14, d_y_15, \
d_y_16, d_y_17, d_y_18}
matrix Om = {u_1, u_2, u_3, u_4, u_5, u_6, u_7, u_8, u_9, u_10, \
u_11, u_12, u_13, u_14, u_15, u_16, u_17, u_18}
matrix omega = transp(Om)*Om /13
matrix Y_1n = transp(Y_1) #transponierte verzögerte Variablenmatrix
matrix d_Yn = transp(d_Y) #transponierte Differenzenmatrix

#Teststatistik:
loop i=1..13 --quiet
    scalar t_rob_$(i)_Z = transp(Y_1n[,,$i])*omega*Y_1n[,,$i]
    scalar t_rob_$(i)_N = transp(Y_1n[,,$i])*d_Yn[,,$i]
end loop

```

```

t_rob_N = 0 #Zähler
t_rob_Z = 0 #Nenner
loop i = 1..13 --quiet
    t_rob_N = t_rob_N + t_rob_$i_N
    t_rob_Z = t_rob_Z + t_rob_$i_Z
end loop

```

```

t_rob = t_rob_N/sqrt(t_rob_Z)
print t_rob

```

Die Testprozedur für das Modell mit Konstante und linearem Trend ist unter „BD-CO2-trend.inp“ auf der beigelegten CD zu finden.

#Trend bereinigen:

#alpha_i1 berechnen:

```

loop i=1..18 --quiet
    a_$i = logCO2_$i[13] - logCO2_$i[1]
    scalar alpha1_$i= a_$i/13
end loop

```

#Variablen berechnen:

```

loop i=1..18 --quiet
    series d_CO2_$i_t = 0
    series z_$i = 0 #rekursive Mittel bestimmen
    z_$i[1] = sum(d_logCO2_$i)
    loop j=2..12
        z_$i[$j] = z_$i[$j-1] - d_logCO2_$i[$j]
    endloop
series CO2_$i_t = logCO2_$i -logCO2_$i[1] -alpha1_$i*time
    loop j=1..13
        d_CO2_$i_t[$j] = sqrt((13-$j)/(14-$j))*(d_logCO2_$i[$j] \
            - (z_$i[$j]/(13-$j)))
    end loop
end loop

```

#verzögerte Variablen definieren

```

loop i=1..18 --quiet
    genr CO2_$i_t_1 = CO2_$i_t(-1)

```

```

    genr d_CO2_$i_t_1 = d_CO2_$i_t(-1)
    genr d_CO2_$i_t_2 = d_CO2_$i_t(-2)
    genr d_CO2_$i_t_3 = d_CO2_$i_t(-3)
end loop

#Pre-Whitening:
#Verzögerte Variablenordnung bestimmen:
loop i=1..18
    ols d_CO2_$i_t CO2_$i_t_1 d_CO2_$i_t_1 d_CO2_$i_t_2 d_CO2_$i_t_3
    scalar t3_$i = $coeff(d_CO2_$i_t_3)/$stderr(d_CO2_$i_t_3)
    ols d_CO2_$i_t CO2_$i_t_1 d_CO2_$i_t_1 d_CO2_$i_t_2
    scalar t2_$i = $coeff(d_CO2_$i_t_2)/$stderr(d_CO2_$i_t_2)
    ols d_CO2_$i_t CO2_$i_t_1 d_CO2_$i_t_1
    scalar t1_$i = $coeff(d_CO2_$i_t_1)/$stderr(d_CO2_$i_t_1)
end loop

#Schätzung der verzögerten Variablenkoeffizienten:
loop i=1..18
    if((t3_$i) < (-1.645))
    ols d_CO2_$i_t CO2_$i_t_1 d_CO2_$i_t_1 d_CO2_$i_t_2 d_CO2_$i_t_3
    genr u_$i=$uhat
    genr a1_$i = $coeff(d_CO2_$i_t_1)
    genr a2_$i = $coeff(d_CO2_$i_t_2)
    genr a3_$i = $coeff(d_CO2_$i_t_3)
    genr y_$i = CO2_$i_t - a1_$i*d_CO2_$i_t_1 - a2_$i*d_CO2_$i_t_2 \
    - a3_$i*d_CO2_$i_t_3
    loop j=1..4 --quiet
        y_$i[$j] = 0
        u_$i[$j] = 0
    end loop

    elif((t2_$i) < (-1.645))
    ols d_CO2_$i_t CO2_$i_t_1 d_CO2_$i_t_1 d_CO2_$i_t_2
    genr u_$i=$uhat
    genr a1_$i = $coeff(d_CO2_$i_t_1)
    genr a2_$i = $coeff(d_CO2_$i_t_2)

```

```

genr y_$i = CO2_$i_t - a1_$i*d_CO2_$i_t_1 - a2_$i*d_CO2_$i_t_2
loop j=1..3 --quiet
    y_$i[$j] = 0
    u_$i[$j] = 0
end loop

    elif((t1_$i) < (-1.645))
ols d_CO2_$i_t CO2_$i_t_1 d_CO2_$i_t_1
genr u_$i=$uhat
genr a1_$i = $coeff(d_CO2_$i_t_1)
genr y_$i = CO2_$i_t - a1_$i*d_CO2_$i_t_1
loop j=1..2 --quiet
    y_$i[$j] = 0
    u_$i[$j] = 0
end loop

    else
ols d_CO2_$i_t CO2_$i_t_1
genr u_$i=$uhat
genr y_$i = CO2_$i_t
endif

genr y_$i_1 = y_$i(-1)
genr d_y_$i = y_$i - y_$i_1
y_$i_1[1]=0
d_y_$i[1]=0
endloop

#Daten als Matrizen abspeichern:
matrix Y_1 = {y_1_1, y_2_1, y_3_1, y_4_1, y_5_1, y_6_1, y_7_1, \
y_8_1, y_9_1, y_10_1, y_11_1, y_12_1, y_13_1, y_14_1, y_15_1, \
y_16_1, y_17_1, y_18_1}
matrix d_Y = {d_y_1, d_y_2, d_y_3, d_y_4, d_y_5, d_y_6, d_y_7, \
d_y_8, d_y_9, d_y_10, d_y_11, d_y_12, d_y_13, d_y_14, d_y_15, \
d_y_16, d_y_17, d_y_18}
matrix Om = {u_1, u_2, u_3, u_4, u_5, u_6, u_7, u_8, u_9, u_10, \

```

```

u_11, u_12, u_13, u_14, u_15, u_16, u_17, u_18}
matrix omega = transp(0m)*0m /13
matrix Y_1n = transp(Y_1) #transponierte verzögerte Variablenmatrix
matrix d_Yn = transp(d_Y) #transponierte Differenzenmatrix

#Teststatistik:
loop i=1..13 --quiet
  scalar t_rob_$i_Z = transp(Y_1n[, $i])*omega*Y_1n[, $i] #Zähler
  scalar t_rob_$i_N = transp(Y_1n[, $i])*d_Yn[, $i] #Nenner
end loop

t_rob_N = 0
t_rob_Z = 0
loop i = 1..13
  t_rob_N = t_rob_N + t_rob_$i_N
  t_rob_Z = t_rob_Z + t_rob_$i_Z
end loop

t_rob = t_rob_N/sqrt(t_rob_Z)
print t_rob

```

A.1.9 Der Test von Jönsen (2005)

Die Testprozedur für das Modell mit Konstante ist unter „Jönsen-CO2-mw.inp“ auf der beigelegten CD zu finden.

```

#Variablen für die GLS Schätzung von alpha_i0 definieren:
loop i=1..18 --quiet
  series C02_$i_m = 0
C02_$i_m[1] = logC02_$i[1]
  loop j=2..13 --quiet
    C02_$i_m[$j] = logC02_$i[$j] -(1-7/13)*logC02_$i[$j-1]
  end loop
end loop
series c_1 = 1
loop j= 2..13 --quiet
  c_1[$j] = 1-(1-7/13)

```

```

end loop

#Schätzung durchführen:
loop i=1..18
  ols CO2_$$i_m c_1
  a0_$$i = $coeff(c_1)
end loop

#Mittelwert bereinigte Reihe generieren:
loop i=1..18 --quiet
  x_$$i = logCO2_$$i - a0_$$i
end loop
x=0
loop i=1..18 --quiet
  x = x + sum(x_$$i)
end loop

loop i=1..18 --quiet
  y_$$i = logCO2_$$i - a0_$$i - 1/18*x
  y_$$i_1 = y_$$i(-1)
  y_$$i_1[1] = 0
end loop

# Slope Schätzer für Beta durchführen:
matrix Y = {y_1, y_2, y_3, y_4, y_5, y_6, y_7, y_8, y_9,\
  y_10, y_11, y_12, y_13, y_14, y_15, y_16, y_17, y_18}
matrix Y_1 = {y_1_1, y_2_1, y_3_1, y_4_1, y_5_1, y_6_1,\
  y_7_1, y_8_1, y_9_1, y_10_1, y_11_1, y_12_1, y_13_1,\
  y_14_1, y_15_1, y_16_1, y_17_1, y_18_1}
matrix Z = mshape(Y,1,234)
matrix Z_1 = mshape(Y_1,1,234)
B = (1/(Z_1*transp(Z_1)))*Z_1*transp(Z)

#Residuen definieren:
loop i=1..18 --quiet
  u_$$i = y_$$i - y_$$i_1*B

```

```

endloop
#Kovarianzmatrix der Residuen definieren:
matrix U = {u_1, u_2, u_3, u_4, u_5, u_6, u_7, u_8, u_9,\
  u_10, u_11, u_12, u_13, u_14, u_15, u_16, u_17, u_18}
matrix SU = (transp(U)*U)/(12)
matrix E = I(13)
matrix Omega = SU ** E

#Standardabweichung des Schätzers definieren:
B2 =(1/(Z_1*transp(Z_1)))*Z_1*Omega*transp(Z_1)*(1/(Z_1*transp(Z_1)))

#Schätzung durchführen:
B_PCSE = (B-1)/sqrt(B2)

Die Testprozedur für das Modell mit Konstante und linearem ist unter „Jönsson-
CO2-trend.inp“ auf der beigelegten CD zu finden.

#Variablen für die GLS Schätzung von alpha_i0 und alpha_i1 definieren:
loop i=1..18 --quiet
  series C02_$i_t = 0
  C02_$i_t[1] = logC02_$i[1]
  loop j=2..13 --quiet
    C02_$i_t[$j] = logC02_$i[$j] - (1-13.5/13)*logC02_$i[$j-1]
  end loop
end loop
series c_2 = 1
loop j= 2..13 --quiet
  c_2[$j] = 1-(1-13.5/13)
end loop
series c_3 = 1
loop j= 2..13
  c_3[$j] = 1-((-13.5)*($j-1))/13
end loop

#Schätzung durchführen:
loop i=1..18
  ols C02_$i_t c_2 c_3

```

```

    genr a0_$i = $coeff(c_2)
    genr a1_$i = $coeff(c_3)
end loop

#Trend bereinigte Reihe generieren:
loop i=1..18 --quiet
    y_$i = logCO2_$i - a0_$i - a1_$i*time
end loop
y=0
loop i=1..18 --quiet
    y = y + sum(y_$i)
end loop

loop i=1..18 --quiet
    y_$i = logCO2_$i - a0_$i - a1_$i*time - 1/18*y
    y_$i_1 = y_$i(-1)
    y_$i_1[1] = 0
end loop

# Slope Schätzer für Beta durchführen:
matrix Y = {y_1, y_2, y_3, y_4, y_5, y_6, y_7, y_8, y_9,\
    y_10, y_11, y_12, y_13, y_14, y_15, y_16, y_17, y_18}
matrix Y1_1 = {y_1_1, y_2_1, y_3_1, y_4_1, y_5_1, y_6_1,\
    y_7_1, y_8_1, y_9_1, y_10_1, y_11_1, y_12_1, y_13_1,\
    y_14_1, y_15_1, y_16_1, y_17_1, y_18_1}
matrix Z = mshape(Y,1,234)
matrix Z_1 = mshape(Y_1,1,234)
B = (1/(Z_1*transp(Z_1)))*Z_1*transp(Z)

#Residuen definieren:
loop i=1..18 --quiet
    u_$i = y_$i - y_$i_1*B
endloop

#Kovarianzmatrix der Residuen definieren:
matrix U = {u_1, u_2, u_3, u_4, u_5, u_6, u_7, u_8, u_9,\
    u_10, u_11, u_12, u_13, u_14, u_15, u_16, u_17, u_18}

```

```

matrix SU = (transp(U)*U)/(12)
matrix E = I(13)
matrix Omega = SU ** E

#Standardabweichung des Schätzers definieren:
B2 =(1/(Z_1*transp(Z_1)))*Z_1*Omega*transp(Z_1)*(1/(Z_1*transp(Z_1)))

#Schätzung durchführen:
B_PCSE = (B-1)/sqrt(B2)

```

A.1.10 Der Test von Chang (2002)

Die Testprozedur für das Modell mit Konstante für das erste Instrument ist unter „Chang-CO2-mw.inp“ auf der beigelegten CD zu finden.

```

#Mittelwert bereinigen:
loop i=1..18 --quiet
CO2_$i_m = logCO2_$i - (1/12)*sum(logCO2_$i_1)#nur Beobachtungen bis t-1
CO2_$i_m_1 =logCO2_$i_1 - (1/12)*sum(logCO2_$i_1)
endloop

#Instrument für verzögerte Variable definieren:
loop i=1..18 --quiet
scalar s_d_y_$i = (1/13)*sum(d_logCO2_$i*d_logCO2_$i)
scalar c_$i = 3/sqrt(13)*sqrt(s_d_y_$i)
F_CO2_$i_m_1 = CO2_$i_m_1*exp(-c_$i*abs(CO2_$i_m_1))
endloop

#Verzögerte Variablenordnung bestimmen:
loop i=1..18 --quiet
    ols CO2_$i_m CO2_$i_m_1 d_logCO2_$i_1 d_logCO2_$i_2 d_logCO2_$i_3
    scalar t3_$i = $coeff(d_logCO2_$i_3)/$stderr(d_logCO2_$i_3)
    ols CO2_$i_m CO2_$i_m_1 d_logCO2_$i_1 d_logCO2_$i_2
    scalar t2_$i = $coeff(d_logCO2_$i_2)/$stderr(d_logCO2_$i_2)
    ols CO2_$i_m CO2_$i_m_1 d_logCO2_$i_1
    scalar t1_$i = $coeff(d_logCO2_$i_1)/$stderr(d_logCO2_$i_1)
end loop

```

```

#Residuen bestimmen und individuelle Teststatistiken berechnen:
loop i=1..18 --quiet
if((t3_$i) < (-1.645))
    ols CO2_$i_m CO2_$i_m_1 d_logCO2_$i_1 d_logCO2_$i_2 d_logCO2_$i_3
    genr e_$i=$uhat

A_$i = sum(F_CO2_$i_m_1* e_$i) - (sum(F_CO2_$i_m_1*d_logCO2_$i_1)\
+ sum(F_CO2_$i_m_1*d_logCO2_$i_2) + sum(F_CO2_$i_m_1*d_logCO2_$i_3))\
/ (sum(d_logCO2_$i_1*d_logCO2_$i_1) + sum(d_logCO2_$i_2*d_logCO2_$i_2)\
+ sum(d_logCO2_$i_3*d_logCO2_$i_3)) * (sum(d_logCO2_$i_1*e_$i)\
+ sum(d_logCO2_$i_2*e_$i) + sum(d_logCO2_$i_3*e_$i))
B_$i = sum(F_CO2_$i_m_1*CO2_$i_m_1) - (sum(F_CO2_$i_m_1*d_logCO2_$i_1)\
+ sum(F_CO2_$i_m_1*d_logCO2_$i_2) + sum(F_CO2_$i_m_1*d_logCO2_$i_3))\
/ (sum(d_logCO2_$i_1*d_logCO2_$i_1) + sum(d_logCO2_$i_2*d_logCO2_$i_2)\
+ sum(d_logCO2_$i_3*d_logCO2_$i_3)) * (sum(d_logCO2_$i_1*CO2_$i_m_1)\
+ sum(d_logCO2_$i_2*CO2_$i_m_1) + sum(d_logCO2_$i_3*CO2_$i_m_1))
C_$i = sum(F_CO2_$i_m_1*F_CO2_$i_m_1) - (sum(F_CO2_$i_m_1*d_logCO2_$i_1)\
+ sum(F_CO2_$i_m_1*d_logCO2_$i_2) + sum(F_CO2_$i_m_1*d_logCO2_$i_3))\
/ (sum(d_logCO2_$i_1*d_logCO2_$i_1) + sum(d_logCO2_$i_2*d_logCO2_$i_2)\
+ sum(d_logCO2_$i_3*d_logCO2_$i_3)) * (sum(d_logCO2_$i_1*F_CO2_$i_m_1)\
+ sum(d_logCO2_$i_2*F_CO2_$i_m_1) + sum(d_logCO2_$i_3*F_CO2_$i_m_1))

alpha_$i = A_$i/B_$i
sigma_$i = (1/13)* sum( e_$i*e_$i)
s_alpha_$i = sigma_$i*C_$i/(B_$i*B_$i)

elif((t2_$i) < (-1.645))
    ols CO2_$i_m CO2_$i_m_1 d_logCO2_$i_1 d_logCO2_$i_2
    genr e_$i=$uhat

A_$i = sum(F_CO2_$i_m_1* e_$i) - (sum(F_CO2_$i_m_1*d_logCO2_$i_1)\
+ sum(F_CO2_$i_m_1*d_logCO2_$i_2)) / (sum(d_logCO2_$i_1*d_logCO2_$i_1)\
+ sum(d_logCO2_$i_2*d_logCO2_$i_2)) * (sum(d_logCO2_$i_1*e_$i)\
+ sum(d_logCO2_$i_2*e_$i))
B_$i = sum(F_CO2_$i_m_1*CO2_$i_m_1) - (sum(F_CO2_$i_m_1*d_logCO2_$i_1)\

```

```

+ sum(F_CO2_$i_m_1*d_logCO2_$i_2)) / (sum(d_logCO2_$i_1*d_logCO2_$i_1)\
+ sum(d_logCO2_$i_2*d_logCO2_$i_2)) * (sum(d_logCO2_$i_1*CO2_$i_m_1)\
+ sum(d_logCO2_$i_2*CO2_$i_m_1))
C_$i = sum(F_CO2_$i_m_1*F_CO2_$i_m_1) - (sum(F_CO2_$i_m_1*d_logCO2_$i_1)\
+ sum(F_CO2_$i_m_1*d_logCO2_$i_2))/ (sum(d_logCO2_$i_1*d_logCO2_$i_1)\
+ sum(d_logCO2_$i_2*d_logCO2_$i_2)) * (sum(d_logCO2_$i_1*F_CO2_$i_m_1)\
+ sum(d_logCO2_$i_2*F_CO2_$i_m_1))

alpha_$i = A_$i/B_$i
sigma_$i = (1/13)* sum( e_$i*e_$i)
s_alpha_$i = sigma_$i*C_$i/(B_$i*B_$i)

elif((t1_$i) < (-1.645))
    ols CO2_$i_m CO2_$i_m_1 d_logCO2_$i_1
    genr e_$i=$uhat

A_$i = sum(F_CO2_$i_m_1* e_$i) - (sum(F_CO2_$i_m_1*d_logCO2_$i_1))\
/ (sum(d_logCO2_$i_1*d_logCO2_$i_1)) * (sum(d_logCO2_$i_1*e_$i))
B_$i = sum(F_CO2_$i_m_1*CO2_$i_m_1) - (sum(F_CO2_$i_m_1*d_logCO2_$i_1))\
/ (sum(d_logCO2_$i_1*d_logCO2_$i_1)) * (sum(d_logCO2_$i_1*CO2_$i_m_1))
C_$i = sum(F_CO2_$i_m_1*F_CO2_$i_m_1) - (sum(F_CO2_$i_m_1*d_logCO2_$i_1))\
/ (sum(d_logCO2_$i_1*d_logCO2_$i_1)) * (sum(d_logCO2_$i_1*F_CO2_$i_m_1))

alpha_$i = A_$i/B_$i
sigma_$i = (1/13)* sum( e_$i*e_$i)
s_alpha_$i = sigma_$i*C_$i/(B_$i*B_$i)

else
    ols CO2_$i_m CO2_$i_m_1
    genr e_$i=$uhat

A_$i = sum(F_CO2_$i_m_1* e_$i)
B_$i = sum(F_CO2_$i_m_1*CO2_$i_m_1)
C_$i = sum(F_CO2_$i_m_1*F_CO2_$i_m_1)

alpha_$i = A_$i/B_$i

```

```

sigma_$i = (1/13)* sum( e_$i*e_$i)
s_alpha_$i = sigma_$i*C_$i/(B_$i*B_$i)

endif
endloop

#IV t-ratio sektor
loop i =1..18 --quiet
    z_$i= alpha_$i/s_alpha_$i
    print z_$i
end loop

#Gesamtstatistik:
Z = 0
loop i=1..18 --quiet
    Z = Z + z_$i
end loop

ZZ= 1/sqrt(18)*Z
print ZZ

Die Testprozedur für das Modell mit Konstante und linearem Trend für das erste
Instrument ist unter „Chang-CO2-trend.inp“ auf der beigelegten CD zu finden.

#Trend bereinigen:
loop i=1..18 --quiet
series m_$i = 0
loop j=1..12 --quiet
    m_$i[$j] = $j*logCO2_$i[$j]
endloop
CO2_$i_t = logCO2_$i + (2/12)*sum(logCO2_$i_1) \
- (6/(13*12))*sum(m_$i) - (1/13)*logCO2_$i[13]
CO2_$i_t_1 = logCO2_$i_1 + (2/12)*sum(logCO2_$i_1) \
- (6/(13*12))*sum(m_$i)
d_CO2_$i_t_1 = d_logCO2_$i_1 - (1/13)*logCO2_$i[13]
d_CO2_$i_t_2 = d_logCO2_$i_2 - (1/13)*logCO2_$i[13]
d_CO2_$i_t_3 = d_logCO2_$i_3 - (1/13)*logCO2_$i[13]

```

```

endloop

#Instrument für verzögerte Variable definieren:
loop i=1..18 --quiet
scalar s_d_y_$i = (1/13)*sum(d_logCO2_$i*d_logCO2_$i)
scalar c_$i = 3/sqrt(13)*sqrt(s_d_y_$i)
F_CO2_$i_t_1 = CO2_$i_t_1*exp(-c_$i*abs(CO2_$i_t_1))
endloop

#Verzögerte Variablenordnung bestimmen:
loop i=1..18 --quiet
  ols CO2_$i_t CO2_$i_t_1 d_CO2_$i_t_1 d_CO2_$i_t_2 d_CO2_$i_t_3
  scalar t3_$i = $coeff(d_CO2_$i_t_3)/$stderr(d_CO2_$i_t_3)
  ols CO2_$i_t CO2_$i_t_1 d_CO2_$i_t_1 d_CO2_$i_t_2
  scalar t2_$i = $coeff(d_CO2_$i_t_2)/$stderr(d_CO2_$i_t_2)
  ols CO2_$i_t CO2_$i_t_1 d_CO2_$i_t_1
  scalar t1_$i = $coeff(d_CO2_$i_t_1)/$stderr(d_CO2_$i_t_1)
end loop

#Residuen bestimmen und individuelle Teststatistiken berechnen:
loop i=1..18 --quiet
if((t3_$i) < (-1.645))
  ols CO2_$i_t CO2_$i_t_1 d_CO2_$i_t_1 d_CO2_$i_t_2 d_CO2_$i_t_3
  genr e_$i=$uhat

A_$i = sum(F_CO2_$i_t_1* e_$i) - (sum(F_CO2_$i_t_1*d_CO2_$i_t_1)\
+ sum(F_CO2_$i_t_1*d_CO2_$i_t_2) + sum(F_CO2_$i_t_1*d_CO2_$i_t_3))\
/ (sum(d_CO2_$i_t_1*d_CO2_$i_t_1) + sum(d_CO2_$i_t_2*d_CO2_$i_t_2)\
+ sum(d_CO2_$i_t_3*d_CO2_$i_t_3)) * (sum(d_CO2_$i_t_1*e_$i) \
+ sum(d_CO2_$i_t_2*e_$i) + sum(d_CO2_$i_t_3*e_$i))
B_$i = sum(F_CO2_$i_t_1*CO2_$i_t_1) - (sum(F_CO2_$i_t_1*d_CO2_$i_t_1)\
+ sum(F_CO2_$i_t_1*d_CO2_$i_t_2) + sum(F_CO2_$i_t_1*d_CO2_$i_t_3))\
/ (sum(d_CO2_$i_t_1*d_CO2_$i_t_1) + sum(d_CO2_$i_t_2*d_CO2_$i_t_2)\
+ sum(d_CO2_$i_t_3*d_CO2_$i_t_3)) * (sum(d_CO2_$i_t_1*CO2_$i_t_1)\
+ sum(d_CO2_$i_t_2*CO2_$i_t_1) + sum(d_CO2_$i_t_3*CO2_$i_t_1))
C_$i = sum(F_CO2_$i_t_1*F_CO2_$i_t_1) - (sum(F_CO2_$i_t_1*d_CO2_$i_t_1)\

```

```

+ sum(F_CO2_$i_t_1*d_CO2_$i_t_2) + sum(F_CO2_$i_t_1*d_CO2_$i_t_3))\
/ (sum(d_CO2_$i_t_1*d_CO2_$i_t_1) + sum(d_CO2_$i_t_2*d_CO2_$i_t_2)\
+ sum(d_CO2_$i_t_3*d_CO2_$i_t_3)) * (sum(d_CO2_$i_t_1*F_CO2_$i_t_1)\
+ sum(d_CO2_$i_t_2*F_CO2_$i_t_1) + sum(d_CO2_$i_t_3*F_CO2_$i_t_1))

alpha_$i = A_$i/B_$i
sigma_$i = (1/13)* sum( e_$i*e_$i)
s_alpha_$i = sigma_$i*C_$i/(B_$i*B_$i)

elif((t2_$i) < (-1.645))
    ols CO2_$i_t CO2_$i_t_1 d_CO2_$i_t_1 d_CO2_$i_t_2
    genr e_$i=$uhat

A_$i = sum(F_CO2_$i_t_1* e_$i) - (sum(F_CO2_$i_t_1*d_CO2_$i_t_1)\
+ sum(F_CO2_$i_t_1*d_CO2_$i_t_2)) / (sum(d_CO2_$i_t_1*d_CO2_$i_t_1)\
+ sum(d_CO2_$i_t_2*d_CO2_$i_t_2)) * (sum(d_CO2_$i_t_1*e_$i)\
+ sum(d_CO2_$i_t_2*e_$i))
B_$i = sum(F_CO2_$i_t_1*CO2_$i_t_1) - (sum(F_CO2_$i_t_1*d_CO2_$i_t_1)\
+ sum(F_CO2_$i_t_1*d_CO2_$i_t_2))/ (sum(d_CO2_$i_t_1*d_CO2_$i_t_1)\
+ sum(d_CO2_$i_t_2*d_CO2_$i_t_2)) * (sum(d_CO2_$i_t_1*CO2_$i_t_1)\
+ sum(d_CO2_$i_t_2*CO2_$i_t_1))
C_$i = sum(F_CO2_$i_t_1*F_CO2_$i_t_1) - (sum(F_CO2_$i_t_1*d_CO2_$i_t_1)\
+ sum(F_CO2_$i_t_1*d_CO2_$i_t_2)) / (sum(d_CO2_$i_t_1*d_CO2_$i_t_1)\
+ sum(d_CO2_$i_t_2*d_CO2_$i_t_2)) * (sum(d_CO2_$i_t_1*F_CO2_$i_t_1)\
+ sum(d_CO2_$i_t_2*F_CO2_$i_t_1))

alpha_$i = A_$i/B_$i
sigma_$i = (1/13)* sum( e_$i*e_$i)
s_alpha_$i = sigma_$i*C_$i/(B_$i*B_$i)

elif((t1_$i) < (-1.645))
    ols CO2_$i_t CO2_$i_t_1 d_CO2_$i_t_1
    genr e_$i=$uhat

A_$i = sum(F_CO2_$i_t_1* e_$i) - (sum(F_CO2_$i_t_1*d_CO2_$i_t_1))\
/ (sum(d_CO2_$i_t_1*d_CO2_$i_t_1)) * (sum(d_CO2_$i_t_1*e_$i))

```

```

B_$i = sum(F_CO2_$i_t_1*CO2_$i_t_1) - (sum(F_CO2_$i_t_1*d_CO2_$i_t_1))\
 / (sum(d_CO2_$i_t_1*d_CO2_$i_t_1)) * (sum(d_CO2_$i_t_1*CO2_$i_t_1))
C_$i = sum(F_CO2_$i_t_1*F_CO2_$i_t_1) - (sum(F_CO2_$i_t_1*d_CO2_$i_t_1))\
 / (sum(d_CO2_$i_t_1*d_CO2_$i_t_1)) * (sum(d_CO2_$i_t_1*F_CO2_$i_t_1))

alpha_$i = A_$i/B_$i
sigma_$i = (1/13)* sum( e_$i*e_$i)
s_alpha_$i = sigma_$i*C_$i/(B_$i*B_$i)

else
  ols CO2_$i_t CO2_$i_t_1
  genr e_$i=$uhat

A_$i = sum(F_CO2_$i_t_1* e_$i)
B_$i = sum(F_CO2_$i_t_1*CO2_$i_t_1)
C_$i = sum(F_CO2_$i_t_1*F_CO2_$i_t_1)

alpha_$i = A_$i/B_$i
sigma_$i = (1/13)* sum( e_$i*e_$i)
s_alpha_$i = sigma_$i*C_$i/(B_$i*B_$i)

endif
endloop

#IV t-ratio sektor
loop i =1..18 --quiet
  z_$i= alpha_$i/s_alpha_$i
  print z_$i
end loop

#Gesamtstatistik:
Z = 0
loop i=1..18 --quiet
  Z = Z + z_$i
end loop
ZZ= 1/sqrt(18)*Z

```

```
print ZZ
```

Für das zweite Instrument wird hier nur die Konstruktion des Instruments angegeben, da sich sonst im Code nichts verändert. Auf der beigelegten CD finden sich die gesamten Skripts unter „Chang-CO2-mw2.inp“ für das Modell mit Konstante und unter „Chang-CO2-trend2.inp“ für das Modell mit Konstante und linearem Trend.

```
loop i=1..18 --quiet
series F_CO2_$i_m_1 = 0
loop j=2..13 --quiet
if(abs(CO2_$i_m_1[$j]) < 3.0)
F_CO2_$i_m_1[$j] = CO2_$i_m_1[$j]*abs(CO2_$i_m_1[$j])
else
    F_CO2_$i_m_1[$j] = 0
endif
endloop
endloop
```

A.2 Die Programmiercodes für die Paneldatenmodelle

Nachdem die Daten für das Fixed und Random Effects Modell geladen sind, müssen auch diese Variablen transformiert werden:

```
logCO2 = log(CO2/Erwerbstatige)
logBW = log(Bruttowertschop/Erwerbstatige)
logBW2 = logBW*logBW
logBW3 = logBW2*logBW
logProd = log(Produktionswert/Erwerbstatige)
logProd2 = logProd*logProd
logProd3 = logProd2*logProd3
```

Die Modelle des „Random und Fixed Effects“ Modell werden durch die folgenden Programmzeilen durchgeführt.

```
#####Bruttowertschöpfung#####
panel logCO2 const logBW logBW2 --random-effects
add logBW3
omit logBW2 logBW3
panel logCO2 const logBW logBW2 --robust # fixed effects
```

```
add logBW3
omit logBW2 logBW3
```

```
#####Produktionswert#####
panel logC02 const logProd logProd2 --random-effects
add logProd3
omit logProd2 logProd3
panel logC02 const logProd logProd2 --robust # fixed effects
add logProd3
omit logProd2 logProd3
```

Der Code für zum Durchführen für die Fixed und Random Effects ist unter „FE-REModelle.inp“ auf der beigelegten CD zu finden.

Für den Dienstleistungssektor und den Industriesektor können dieselben Codes verwendet werden, wenn die entsprechenden Datensätze statt „AlleSektoren.gdt“ geladen werden.

Für die Landwirtschaft wird der folgende Code „Landwirtschaft.inp“ zum Durchführen einer robusten Schätzung verwendet.

```
#####Bruttowertschöpfung#####
ols logC02 const logBW logBW2 --robust
add logBW3
omit logBW2 logBW3
```

```
#####Produktionswert#####
ols logC02 const logProd logProd2 --robust
add logProd3
omit logProd2 logProd3
```

Anhang B

Der Inhalt der CD

Auf der beigelegten CD finden sich drei Ordner.

Der erste Ordner „NAMEA Daten“ beinhaltet das PDF-File der Originaldaten der NAMEA, sowie zwei Excel-Files mit welchen die Daten in Gretl oder ein anderes Programmierprogramm eingelesen werden können.

- Integrierte_Namea_1995-2007.pdf
- AlleSektoren1995-2007.xls
- AlleSektoren -gruppenweise.xls

Der zweite Ordner „Panelmodelle“ beinhaltet alle notwendigen Files zum Durchführen der Modellschätzungen des sechsten Kapitels.

- Alle Sektoren.gdt
- Landwirtschaft.gdt
- Industrie.gdt
- Dienstleistung.gdt
- FEREModelle.inp
- Landwirtschaft.inp

Der dritte Ordner „Einheitswurzeltests“ beinhaltet alle Codes zur Durchführung der Tests des fünften Kapitels.

Das Gretl-Datenfile „AlleSektoren-gruppenweise.gdt“ wird für das Durchführen

aller Tests benötigt. Das Skript „Datenmodellieren.inp“ passt die Daten zur Durchführung aller Test-Skripts an.

Im Weiteren enthält dieser Ordner zwei Unterordner, welche die Codes der Einheitswurzeltests der ersten Generation und der zweiten Generation beinhalten.

Die erste Generation:

- LLC-CO2-mw.inp
- LLC-CO2-trend.inp
- IPS-CO2.inp
- Fisher-CO2.inp

Die zweite Generation:

- BD-CO2-mw.inp
- BD-CO2-trend.inp
- BN-CO2-mw.inp
- BN-CO2-trend.inp
- Chang-CO2-mw.inp
- Chang-CO2-mw2.inp
- Chang-CO2-trend.inp
- Chang-CO2-trend2.inp
- Choi-CO2-mw.inp
- Choi-CO2-trend.inp
- Info-CO2.inp
- Jönsson-CO2-mw.inp
- Jönsson-CO2-trend.inp
- Pesaran-CO2.inp

Literaturverzeichnis

- [1] AKBOSTANCI, E. ; TÜRÜT-ASIK, S. ; TUNC, G. I.: The Relationship between Income and Environment in Turkey: Is there an Environmental Kuznets Curve? In: *Energy Policy*, Vol. 37 (2009)
- [2] ALDY, J. E.: An Environmental Kuznets Curve Analysis of U.S. State-Level Carbon Dioxide Emissions. In: *The Journal of Environment and Development*, Vol. 14 (2005)
- [3] ARRELANO, M.: *Panel Data Econometrics*. Bd. Vol. 1. Oxford, Oxford University Press, 2003
- [4] ARROW, K. ; BOLIN, B. ; COSTANZA, R. ; DASGUPTA, P. ; FOLKE, C. ; HOLLING, C. S. ; JANSSON, B.-O. ; LEVIN, S. ; MÄLER, K.-G. ; PERRINGS, C. A. ; PIMENTEL, D.: Economic Growth, Carrying Capacity, and the Environment. In: *Science*, Vol. 263 (1995)
- [5] BAI, J.: Estimating Cross-Section Common Stochastic Trends in Nonstationary Panel Data. In: *Journal of Econometrics*, Vol. 122 (2004)
- [6] BAI, J. ; NG, S.: Determining the Number of Factors in Approximate Factor Models. In: *Econometrica*, Vol. 70 (2002)
- [7] BAI, J. ; NG, S.: A PANIC Attack on Unit Roots and Cointegration. In: *Econometrica*, Vol. 72 (2004)
- [8] BAI, J. ; NG, S.: A new Look at Panel testing of stationarity and the PPP Hypotheses. In: ANDREWS, D. W. K. (Hrsg.) ; STOCK, J. H. (Hrsg.): *Identification and Inference for Econometric Models: Essays in the Honor of Thomas J. Rothenberg*,. Cambridge, Cambridge University Press, 2005
- [9] BAI, J. ; NG, S.: Panel Unit Root Tests with Cross-Section Dependence: A Further Investigation. In: *Econometric Theory*, Vol. 26 (2010)

- [10] BARBIERI, L.: *Panel Unit Root Tests: A Review*. 2005. – Università Cattolica del Sacro Cuore
- [11] BAUD, S. ; MILOTA, E.: *Standard-Dokumentation Metainformationen (Definitionen, Erläuterungen, Methoden, Qualität) zur Integrierten NAMEA 1995-2006*. 2009. – Statistik Austria
- [12] BAUD, Sacha: *Integrierte NAMEA 1995-2007, Projektbericht*. 2009. – Statistik Austria
- [13] BREITUNG, J.: The Local Power of some Unit Root Tests for Panel Data. In: BALTAGI, B. (Hrsg.): *Nonstationary Panels, Panel Cointegration, and Dynamic Panels, Volume 15 (Advances in Econometrics)*. JAI Press, 2000
- [14] BREITUNG, J. ; DAS, S.: Panel Unit Root Tests under Cross Sectional Dependence. In: *Statistica Neerlandica*, Vol. 59 (2005)
- [15] BREITUNG, J. ; DAS, S.: Testing for Unit Roots in Panels with a Factor Structure. In: *Econometric Theory*, Vol. 24 (2008)
- [16] BREITUNG, J. ; PESARAN, M. H.: Unit Roots and Cointegration in Panels. In: MÁTYÁS, L. (Hrsg.) ; SEVESTRE, P. (Hrsg.): *The Econometrics of Panel Data (3rd Edition)*. Springer, 2008
- [17] CHANG, Y.: Nonlinear IV Unit Root Tests in Panels with Cross-Sectional Dependency. In: *Journal of Econometrics*, Vol. 110 (2002)
- [18] CHANG, Y.: Bootstrap Unit Root Tests in Panels with Cross-Sectional Dependency. In: *Journal of Econometrics*, Vol. 120 (2004)
- [19] CHANG, Y. ; PARK, J.Y. ; PHILLIPS, P.C.B.: Nonlinear Econometric Models with Cointegrated and Deterministically Trending Regressors. In: *Econometric Journal*, Vol. 4 (2001)
- [20] CHOI, I.: Unit Root Tests for Panel Data. In: *Journal of International Money and Finance*, Vol. 20 (2001)
- [21] CHOI, I.: Combination Unit Root Tests for Cross Sectionally Correlated Panels. In: *Econometric Theory and Practice: Frontiers of Analysis and Applied Research: Essays in Honor of Peter C. B. Phillips*,. Cambridge, Cambridge University Press, 2002

- [22] CHOI, I. ; CHUE, T.: Subsampling Hypothesis Tests for Nonstationary Panels with Applications to Exchange Rates and Stock Prices. In: *Journal of Applied Econometrics*, Vol. 22 (2007)
- [23] CHOWDHURY, R. R. ; MORAN, E. F.: Turning the curve: A critical review of Kuznets approaches. In: *Applied Geography*, (2010)
- [24] DASGUPTA, S. ; LAPLANTE, B. ; WANG, H. ; WHEELER, D.: Confronting the Environmental Kuznets Curve. In: *Journal of Economic Perspectives*, Vol. 16 (2002)
- [25] DICKEY, D. A. ; FULLER, W. A.: Distribution of the Estimators for Autoregressive Time Series with a Unit Root. In: *Journal of American Statistical Association*, Vol. 74 (1979)
- [26] DIJKGRAAF, E. ; VOLLEBERGH, H.: A Test for Parameter Homogeneity in CO2 Panel EKC Estimations. In: *Environmental and Resource Economics*, Vol. 32 (2005)
- [27] DINDA, S.: Environmental Kuznets Curve Hypothesis: A Survey. In: *Ecological Economics*, Vol. 49 (2004)
- [28] EGLI, H.: *Are cross-country Studies of the Environmental Kuznets Curve misleading? New Evidence from Time Series Data for Germany.* 2002. – Working Paper,
- [29] ELLIOTT, G. ; ROTHENBERG, T. J. ; STOCK, J. H.: Efficient Tests for an Autoregressive Unit Root. In: *Econometrica*, Vol. 64 (1996)
- [30] ENGLE, R. F. ; GRANGER, C. W. J.: Co-Integration and Error Correction: Representation, Estimation, and Testing. In: *Econometrica*, Vol. 55 (1987)
- [31] FODHA, M. ; ZAGHDOUD, O.: Economic Growth and Pollutant Emissions in Tunisia: An empirical Analysis of the Environmental Kuznets Curve,. In: *Energy Policy*
- [32] FRIEDL, B. ; GETZNER, M.: Determinants of CO2 Emissions in a small Open Economy,. In: *Ecological Economics*,
- [33] GALEOTTI, M. ; MANERA, M. ; LANZA, A.: On the Robustness of Robustness Checks of the Environmental Kuznets Curve Hypothesis. In: *Environment Resource Economics*, Vol. 42 (2009)

- [34] GENGENBACH, C. ; PALM, F. ; URBAIN, J-P.: Panel Unit Root Tests in the Presence of Cross-Sectional Dependencies: Comparison and Implications for Modelling. In: *Econometric Reviews* Vol. 29 (2010)
- [35] GREENE, W.H.: *Econometric Analysis*. Bd. Vol. 8. New Jersey, Pearson Prentice Hall, 2008
- [36] GROOT, H. de ; WITHAGEN, C. A. ; MINLIANG, Z.: Dynamics of China's Regional Development and Pollution: an Investigation into the Environmental Kuznets Curve. In: *Environment and Development Economics*, Vol. 9 (2001)
- [37] GROSSMAN, G. M. ; KRUEGER, A.B.: *Environmental Impacts of a North American Free Trade Agreement*. 1991. – Working Paper
- [38] GUTTIERREZ, L.: Panel Unit Root Tests for Cross-sectionally Correlated Panels: A Monte Carlo Comparison. In: *Oxford Bulletin of Economics and Statistics*, Vol. 68 (2006)
- [39] HALL, A.: Testing for a Unit Root in Time Series With Pretest Data-Based Model Selection. In: *Journal of Business and Economic Statistics*, Vol. 12 (1994)
- [40] HE, J. ; RICHARD, P.: Environmental Kuznets Curve for CO₂ in Canada. In: *Ecological Economics*, Vol. 69 (2010)
- [41] HUBER, P. J.: *Robust Statistics*. 1981. – New York: John Wiley and Sons
- [42] IM, K. S. ; PESARAN, M. H. ; SHIN, Y.: Testing for Unit Roots in Heterogeneous Panels. In: *Journal of Econometrics*, Vol. 115 (2003)
- [43] IM, K. S. ; PESARAN, M.H.: *On the Panel Unit Root Tests using Nonlinear Instrumental Variables*. 2003. – Cambridge Working Papers in Economics
- [44] JÖNSSON, K.: Cross-Sectional Dependency and Size Distortion in a Small-Sample Homogeneous Panel Data Unit Root Test. In: *Oxford Bulletin of Economics and Statistics* Vol. 67 (2005)
- [45] KAO, C.: Spurious Regression and Residual Based Tests for Cointegration in Panel Data. In: *Journal of Econometrics*, Vol. 115 (1999)
- [46] KIJIMA, M. ; NISHIDE, K. ; OHYAMA, A.: Economic Models for the Environmental Kuznets Curve: A Survey. In: *Journal of Economic Dynamics and Control*, Vol. 34 (2010)

- [47] KUZNETS, S.: Economic Growth and Income Inequality. In: *American Economic Review*, Vol. 49 (1955)
- [48] LEKAKIS, J. N.: Environment and Development in a Southern European Country: which Environmental Kuznets Curve? In: *Journal of Environmental Planning and Management*, Vol. 43 (2000)
- [49] LEVIN, A. ; LIN, C.-F. ; CHU, C.-S.: Unit Root Tests in Panel Data: Asymptotic and Finite-sample Properties. In: *Journal of Econometrics*, Vol. 108 (2002)
- [50] LOPEZ, C.: A Panel Unit Root Test with good Power in small Samples. In: *Econometric Reviews*, Vol. 28 (2009)
- [51] MADDALA, G. S. ; WU, S.: A Comparative Study of Unit Root Tests with Panel Data and a New Simple Test. In: *Oxford Bulletin of Economics and Statistics*, Special Issue (1999)
- [52] MALLOWS, C. L.: Some Comments on Cp. In: *Technometrics*, Vol. 8 (1973)
- [53] MAZZANTI, M. ; MARIN, G.: Emissions Trends and Labour Productivity Dynamics Sector Analyses of De-coupling/Recoupling on a 1990-2005 NAMEA. In: *Nota di Lavoro*, (2009)
- [54] MAZZANTI, M. ; MONTINI, A. ; ZOBOLI, R.: Environmental Kuznets Curves for Air Pollutant Emissions in Italy: Evidence from Environmental Accounts (NAMEA) Panel Data. In: *Economic Systems Research*, Vol. 20 (2008)
- [55] MAZZANTI, M. ; MUSOLESI, A. ; ZOBOLI, R.: A Panel data heterogeneous Bayesian Estimation of Environmental Kuznets Curves for CO2 Emissions. In: *Applied Economics*, Vol. 42 (2010)
- [56] MILLIMET, D. L. ; LIST, J. A. ; STENGOS, T.: The Environmental Kuznets Curve: Real Progress or misspecified Models? In: *Review of Economics and Statistics*, Vol. 85 (2003)
- [57] MOON, H. R. ; PERRON, B.: Testing for a Unit Root in Panel with Dynamic Factors. In: *Journal of Econometrics*, Vol. 122 (2004)
- [58] MOON, H. R. ; PERRON, P.: An Empirical Analysis of Nonstationarity in a Panel of Interest Rates with Factors. In: *Journal of Applied Econometrics*, Vol. 22 (2007)

- [59] MOON, H. R. ; PERRON, P. ; PHILLIPS, P. C. B.: Incidental Trends and the Power of Panel Unit Root Tests. In: *Journal of Econometrics*, Vol.141 (2007)
- [60] N.BECK ; KATZ, J. N.: What do to (and not do do) with Time-Series Cross-Section Data. In: *The American Political Science Review*, Vol. 89 (1995)
- [61] PANAYOTOU, T.: *Empirical Tests and Policy Analysis of Environmental Degradation at different Stages of Economic Development*. 1993. – Working Paper
- [62] PAPELL, D. H. ; THEODORIDIS, H.: The Choice of Numeraire Currency in Panel Tests of Purchasing Power Parity. In: *Journal of Money, Credit and Banking*, Vol. 33 (2001)
- [63] PARK, J.Y. ; PHILLIPS, P.C.B.: Asymptotics for Nonlinear Transformations of Integrated Time Series. In: *Econometric Theory*, Vol. 15 (1999)
- [64] PARK, J.Y. ; PHILLIPS, P.C.B.: Nonlinear Regressions with Integrated Time Series. In: *Econometrica*, Vol. 69 (2001)
- [65] PEDRONI, P.: Panel cointegration. Asymptotic and finite sample properties of pooled time series tests with an application to the PPP hypothesis. In: *Econometric Theory*, Vol. 20 (2004)
- [66] PESARAN, M. H.: A Simple Panel Unit Root Test in the Presence of Cross-Section Dependence. In: *Journal of Applied Econometrics*, 22 (2007)
- [67] PHILLIPS, P. C. B. ; SUL, D.: Dynamic Panel Estimation and Homogeneity Testing under Cross Section Dependence. In: *Econometrics Journal*, Vol. 6 (2003)
- [68] ROCA, J.: Do individual Preferences explain the Environmental Kuznets Curve? In: *Ecological Economics*, Vol. 45 (2003)
- [69] ROCA, J. ; PADILLA, E. ; FARRE, M. ; GALLETTO, V.: The Relationship between Income and Environment in Turkey: Is there an Environmental Kuznets Curve? In: *Ecological Economics*, Vol. 37 (2001)
- [70] SCHMALENSEE, R. ; STOKER, T. M. ; JUDSON, R. A.: World Carbon Dioxide Emissions: 1950-2050. In: *Review of Economics and Statistics*, Vol. 80 (1998)

- [71] SCHMIDT, P. ; PHILLIPS, P. C. B.: LM tests for a Unit Root in the Presence of Deterministic Trends. In: *Oxford Bulletin of Economics and Statistics*, Vol. 54 (1992)
- [72] SHAFIK, N. ; BANDYOPADHYAY, S.: *Economic Growth and Environmental Quality: Time Series and Crosscountry Evidence*. 1992. – Background Paper for the World Development Report 1992, The World Bank, Washington, DC.
- [73] SHIN, D. W. ; KANG, S.: An Instrumental Variable Approach for Panel Unit Root Tests under Cross Sectional Dependence. In: *Journal of Econometrics*, Vol. 134 (2006)
- [74] SHIN, D. W. ; KANG, S. ; OH, M.-S.: Recursive Mean Adjustment for Panel Unit Root Tests. In: *Econometric Letters*, Vol. 84 (2004)
- [75] SHIN, D. W. ; SO, B. S.: Recursive Mean Adjustment in Time-Series Inferences. In: *Statistics and Probability Letters*, Vol. 43 (1999)
- [76] SMITH, V. ; LEYBOURNE, S. ; KIM, T.-H. ; NEWBOLD, P.: More Powerful Panel Data Unit Root Tests with an Application to Mean Reversion in Real Exchange Rates. In: *Journal of Applied Econometrics*, Vol. 19 (2004)
- [77] STERN, D. I.: Progress on the Environmental Kuznets Curve? In: *Environment and Development Economics*, Vol. 3 (1998)
- [78] STERN, D. I.: Explaining Changes in Global Sulfur Emissions: An Econometric Decomposition Approach. In: *Ecological Economics*, Vol. 42 (2002)
- [79] STERN, D. I.: The Rise and Fall of the Environmental Kuznets Curve. In: *World Development*, Vol. 32 (2004)
- [80] STERN, D. I. ; COMMON, M. S.: Is there an Environmental Kuznets Curve for Sulfur? In: *Journal of Environmental Economics and Management*, Vol. 41 (2001)
- [81] STERN, D. I. ; COMMON, M. S. ; BARBIER, E. B.: Economic Growth and Environmental Degradation: A Critique of the Environmental Kuznets Curve. In: *World Development*, Vol. 24 (1996)
- [82] STOCK, J. S. ; WATSON, M.: Variable Trends in Economic Time Series. In: *Journal of Economic Perspectives*, Vol. 2 (1988)

- [83] T. MYLLYNTAUS, J. K.: Anxiety and Technological Change — Explaining the inverted U-curve of Sulphur Dioxide Emissions in late 20th century Finland. In: *Ecological Economics*, Vol. 69 (2010)
- [84] WACHTER, S. de ; HARRIS, R. D. F. ; TZAVALIS, E.: Panel Data Unit Root Tests: The Role of Serial Correlation and Time Dimension. In: *Journal of Statistical Planning and Inference*, Vol. 137 (2007)
- [85] WAGNER, M.: The Carbon Kuznets Curve: A Cloudy Picture Emitted by Bad Econometrics? In: *Resource and Energy Economics* 30 (2008)
- [86] WAGNER, M. ; MÜLLER-FÜRSTENBERGER, G.: *The Carbon Kuznets Curve: A Cloudy Picture Emitted by Bad Econometrics?* 2004. – Working Paper Economic Series 197, Institute for Advanced Studies Vienna
- [87] WAGNER, M. ; MÜLLER-FÜRSTENBERGER, G. ; MÜLLER, B.: *Exploring the Carbon Kuznets Hypothesis*. 2004. – Working Paper
- [88] WOOLDRIDGE, J. M.: *Econometric Analysis of Cross Section and Panel Data*. Bd. Vol. 13. Cambridge, MA: MIT Press, 2002