

Aspekte der Konjunkturprognose
Modellierung, Vorhersage und Datenqualität des
Bruttoinlandsprodukts



Inaugural-Dissertation zur Erlangung des Grades eines Doktors der
Wirtschafts- und Sozialwissenschaften der Wirtschafts- und
Sozialwissenschaftlichen Fakultät der Christian-Albrechts-Universität
zu Kiel

vorgelegt von

Diplom-Volkswirt Jens Hogrefe
aus Rotenburg (Wümme)

Kiel 2008

Gedruckt mit Genehmigung der
Wirtschafts- und Sozialwissenschaftlichen Fakultät
der Christian-Albrechts-Universität zu Kiel

Dekan:
Prof. Dr. Helmut Herwartz

Erstberichterstattender:
Prof. Dr. Roman Liesenfeld

Zweitberichterstattender:
Prof. Dr. Thomas Lux

Tag der Abgabe der Arbeit:
30. Januar 2008

Tag der mündlichen Prüfung:
23. Mai 2008

Vorwort

Die vorliegende Arbeit ist während meiner Tätigkeit am Institut für Statistik und Ökonometrie der Christian-Albrechts-Universität zu Kiel entstanden. Kapitel 4, welches die Volatilitätsreduktion des deutschen Bruttoinlandsproduktwachstums diskutiert, basiert auf einer gemeinsamen Arbeit mit Herrn Prof. Dr. Roman Liesenfeld und Herrn Dipl.-Vw. Christian Aßmann.

Mein besonderer Dank gilt meinem akademischen Lehrer und Doktorvater Herrn Prof. Dr. Roman Liesenfeld, der den Anstoß für diese Arbeit gab und mir immer wieder mit wertvollen Anregungen und hilfreicher Kritik zur Seite stand. Insgesamt habe ich am Institut für Statistik und Ökonometrie eine freundliche und sehr produktive Arbeitsatmosphäre erlebt und von ihr profitiert, die geprägt war von akademischer Freiheit und gegenseitigem wissenschaftlichem Interesse. Hierfür möchte sowohl den Leitern des Instituts Herrn Prof. Dr. Roman Liesenfeld und Herrn Prof. Dr. Helmut Herwartz sowie Prof. em. Dr. Gerd Hansen als auch den übrigen Mitgliedern des Instituts, die ich in meiner Zeit erleben durfte, ganz ausdrücklich danken. Ich bedanke mich ebenfalls bei Herrn Prof. Dr. Thomas Lux für die Übernahme des Zweitgutachtens.

Zu großem Dank verpflichtet bin ich an dieser Stelle Herrn Dipl. Vw. Christian Aßmann. Wir haben viele gemeinsame Projekte in Forschung und Lehre vorangetrieben, und ich hatte in ihm stets einen kompetenten Diskussionspartner sowie eine Anlaufadresse für diverse Fragen in den Bereichen Textverarbeitung, MATLAB und Dart. Danken möchte ich Frau cand. sc. pol. Katharina Beyerlein und Frau cand. sc. pol. Sara Kutzner für die mit großer Sorgfalt durchgeführte Aufgabe des Korrekturlesens.

Schließlich möchte ich mich bei Frau Pastorin Janina Boysen für ihre immer währende Unterstützung und Nachsicht bedanken.

Kiel, am 12. Juni 2008

Jens Hogrefe

Inhaltsverzeichnis

Abbildungsverzeichnis	vi
Tabellenverzeichnis	ix
1 Einleitung	1
1.1 Gegenstand und Ziel der Arbeit	1
1.2 Definition von Konjunktur und Konjunkturzyklus	4
1.3 Aufbau der Arbeit	6
2 Zeitreihenmodelle des BIP-Wachstums	8
2.1 Modelldarstellung und Maximum Likelihood Schätzung	9
2.1.1 Lineare Modelle	9
2.1.2 Markov-Switching-Modelle	10
2.1.3 Bounce-Back-Modell	12
2.1.4 SETAR-Modell	12
2.1.5 Floor-Ceiling-Modell	13
2.1.6 Regime-Wechsel-Modell	16
2.2 Daten zum BIP-Wachstum in Deutschland	19
2.3 Literaturübersicht zu nicht-linearen Zeitreihenmodellen für deutsche BIP-Daten .	20
2.4 Schätzergebnisse	21
2.5 Bayesianische Modellevaluation	30
2.5.1 Probleme frequentistischer Inferenz nicht-linearer Modelle	30
2.5.2 Marginale Likelihood	32
2.5.3 Markov-Chain-Monte-Carlo-Methoden	33
2.5.4 Berechnen der Marginale Likelihood	37
2.5.5 Ergebnisse	40

2.6	Prognosegüte	41
2.6.1	Prognose in nicht-linearen Modellen	41
2.6.2	Evaluation von Punktprognosen	42
2.6.3	Evaluation von Intervallprognosen	44
2.6.4	Prognoseergebnisse	46
3	Reproduktion der Konjunkturzykluseigenschaften	54
3.1	Konjunkturzykluseigenschaften als Stilisierte Fakten	54
3.2	Asymmetrien im deutschen Konjunkturverlauf	56
3.2.1	Formen der Asymmetrie	56
3.2.2	Tests auf Asymmetrie	57
3.3	Datierung von Wechsellpunkten der Konjunktur	60
3.4	Simulationsergebnisse	62
3.5	Die Bedeutung nicht-linearer Zeitreihenmodelle im deutschen Kontext	68
4	Die Verminderung der Volatilität des BIP-Wachstums	70
4.1	Einleitung	70
4.2	Auffinden und Datieren des Strukturbruchs	72
4.2.1	Modellspezifikationen	72
4.2.2	Ergebnisse	74
4.3	Ursachen für die Volatilitätsreduktion	81
4.3.1	Volatilität der Komponenten des BIP	82
4.3.2	Strukturwandel	85
4.4	Schluss	90
5	Zeitvariierende Vorlaufeigenschaften von Frühindikatoren	92
5.1	Frühindikatoren in der Konjunkturforschung	92
5.1.1	Was ist ein Frühindikator?	92
5.1.2	Frühindikatoren und Vorhersagemodelle	95
5.2	Die Zinsdifferenz als Frühindikator der Konjunktur	99
5.2.1	Lineares Vorhersagemodell	99
5.2.2	Nicht-Linearität und Instabilität der Vorlaufeigenschaften	99
5.2.3	Warum ist die Zinsdifferenz ein Frühindikator?	100
5.2.4	Empirische Ergebnisse zeitvariierender Vorlaufeigenschaften	102
5.3	Die Rolle der Geldpolitik	113

5.3.1	Empirische Reaktionsfunktionen der Geldpolitik	113
5.3.2	Zeitvariation der Geldpolitik	114
5.3.3	Gemeinsames Markov-Switching-Modell	118
5.3.4	Ergebnisse	120
5.3.5	Schluss	130
6	Echtzeitdaten und die Vorhersage von Datenrevisionen	132
6.1	Echtzeitdaten und Datenrationalität	133
6.2	Modelle mit gemischtfrequenten Daten	136
6.2.1	Interpolation	136
6.2.2	Zustandsraummodelle und der Kalman-Filter	137
6.2.3	MIDAS	138
6.3	Vorhersage von Datenrevisionen	139
6.3.1	Vorhersagemodelle	140
6.3.2	Datenrevisionen des realen Outputs der USA	142
6.3.3	Datenrevisionen des deutschen BSP	158
7	Zusammenfassende Schlussfolgerung	166
A	Methoden	169
A.1	Hamilton-Filter und Kim-Glätter	169
A.2	Gibbs-Sampler der Zeitreihenmodelle	171
A.3	Die Skala von Jeffreys	179
A.4	Varianzbruch und Gibbs-Sampler	179
A.5	Marginale Likelihood für ein Modell mit Bruch in der Kovarianz	182
A.6	Gibbs-Sampler des Gemeinsamen Markov-Switching-Modells	183
A.7	Dynamisches Faktormodell	185
A.8	Echtzeitdaten – USA	188
	Literaturverzeichnis	190

Abbildungsverzeichnis

2.1	Regressoren im Floor-Ceiling-Modell	15
2.2	Spannungsindex im DLR-Modell – $\delta = 0,575$	17
2.3	Quartalswachstumsraten des deutschen BIP	20
2.4	Zustandswahrscheinlichkeiten MSA und MSAH	27
2.5	Zustandswahrscheinlichkeiten MSI und MSIH	29
2.6	Zustandswahrscheinlichkeiten Bounce-Back-Modell	29
2.7	SETAR-Modell und DLR-Modell	30
3.1	Eigenschaften des Konjunkturzyklus	56
4.1	A posteriori Verteilungen des Bruchs	80
4.2	Anteile der Komponenten der Entstehungsseite am BIP	86
5.1	Homoskedastische MS-Modelle – USA	106
5.2	Lineares Modell mit MS-Varianz – USA	106
5.3	MS-Modell mit MS-Varianz – USA	108
5.4	Restringiertes MS-Modell mit MS-Varianz – USA	108
5.5	Homoskedastische MS-Modelle – Deutschland	111
5.6	Lineares Modell mit MS-Varianz – Deutschland	112
5.7	MS-Modell mit MS-Varianz – Deutschland	112
5.8	Restringiertes MS-Modell mit MS-Varianz – Deutschland	113
5.9	Markov-Switching-Modell der Geldpolitik – USA	116
5.10	Markov-Switching-Modell der Geldpolitik – Deutschland	117
5.11	Gemeinsames Markov-Switching-Modell – USA – Teil (a)	120
5.12	Gemeinsames restringiertes Markov-Switching-Modell – USA – Teil (a)	123
5.13	Gemeinsames Markov-Switching-Modell – USA – Teil (b)	123
5.14	Gemeinsames restringiertes Markov-Switching-Modell – USA – Teil (b)	124

5.15	Gemeinsames Markov-Switching-Modell – Deutschland – Teil (a)	126
5.16	Gemeinsames Markov-Switching-Modell – Deutschland – Teil (b)	129
5.17	Gemeinsames restringiertes Markov-Switching-Modell – Deutschland – Teil (b)	129
6.1	Datenrevisionen – USA	143
6.2	Datenrevisionen – Deutschland	159

Tabellenverzeichnis

2.1	Schätzergebnisse des AR-, MSA- und MSAH-Modells	22
2.2	Schätzergebnisse des MSI-, MSIH- und Bounce-Back-Modells	25
2.3	Schätzergebnisse des SETAR-, Floor-Ceiling- und DLR-Modells	28
2.4	Marginale Likelihood	40
2.5	Relative MSE der Prognosen	46
2.6	Test auf gleiche Prognosegüte (Diebold und Mariano [1995])	49
2.7	Encompassing-Test (Harvey et al. [1998])	50
2.8	Test auf gleiche Prognosegüte genisteter Modelle (Clark und West [2007])	51
2.9	Test auf unbedingte korrekte Überdeckung	51
2.10	Test auf zeitliche Unabhängigkeit der Überdeckung	52
2.11	Test auf bedingte korrekte Überdeckung	52
3.1	Tests auf Dauerabhängigkeit	60
3.2	Simulationsergebnisse der BIP-Wachstums-Modelle – Mediane und empirische Verteilungsfunktion	64
3.3	Simulationsergebnisse der BIP-Wachstums-Modelle – relative Häufigkeit der Akzeptanzregionen in %	67
4.1	Log Marginale Likelihoods	74
4.2	Bayesianische Schätzung des AR-Modells mit Bruch in der Varianz	75
4.3	Bayesianische Schätzung des MS-Modells mit Bruch in der Varianz	77
4.4	Bayesianische Schätzung des DLR-Modells mit Bruch in der Varianz	79
4.5	Stichprobenstatistiken des BIP-Wachstums und der Komponenten	83
4.6	Log-Bayes-Faktoren für Varianzbrüche in den Komponenten	84
4.7	Bayesianische Analyse der kontrafaktischen Zeitreihen	85
4.8	Bayesianische Analyse der paarweisen Korrelationen - Entstehungsseite	87
4.9	Strukturbruch in paarweisen Korrelationen	88

4.10	Bayesianische Analyse der paarweisen Korrelationen - Verwendungsseite	89
5.1	Ergebnisse für das Vorhersagemodell – USA – Teil (a)	105
5.2	Ergebnisse für das Vorhersagemodell – USA – Teil (b)	107
5.3	Ergebnisse für das Vorhersagemodell – Deutschland – Teil (a)	109
5.4	Ergebnisse für das Vorhersagemodell – Deutschland – Teil (b)	110
5.5	Gemeinsames Markov-Switching-Modell – USA – Teil (a)	121
5.6	Gemeinsames Markov-Switching-Modell – USA – Teil (b)	122
5.7	Marginale Likelihood – Modellevidenz	125
5.8	Gemeinsames Markov-Switching-Modell – Deutschland – Teil (a)	127
5.9	Gemeinsames Markov-Switching-Modell – Deutschland – Teil (b)	128
6.1	Vorhersagemodelle für Langzeitrevisionen des BIP-Wachstums in der USA gegeben A	145
6.2	Vorhersagemodelle für Langzeitrevisionen des BIP-Wachstums in der USA gegeben B	146
6.3	Vorhersagemodelle für Langzeitrevisionen des BIP-Wachstums in der USA gegeben C	147
6.4	Vorhersagemodelle für Kurzzeitrevisionen des BIP-Wachstums in der USA gegeben A	148
6.5	Vorhersagemodelle für Kurzzeitrevisionen des BIP-Wachstums in der USA gegeben B	149
6.6	Vorhersagemodelle für Kurzzeitrevisionen des BIP-Wachstums in der USA gegeben C	150
6.7	MSFE – Langzeitrevisionen – USA	152
6.8	Diebold-Mariano-Test – Langzeitrevisionen – USA	153
6.9	MSFE – Langzeitrevisionen nach der ersten Revision (C) – USA	154
6.10	Diebold-Mariano-Test – Langzeitrevisionen nach der ersten Revision (C) – USA .	154
6.11	MSFE – Kurzzeitrevisionen – USA	155
6.12	Diebold-Mariano-Test – Kurzzeitrevisionen – USA	156
6.13	MSFE – Kurzzeitrevisionen nach der ersten Revision (C) – USA	156
6.14	Diebold-Mariano-Test – Kurzzeitrevisionen nach der ersten Revision (C) – USA .	157
6.15	Vorhersagemodelle für Kurzzeitrevisionen des BSP-Wachstums in Deutschland gegeben A bzw. B	161

6.16 Vorhersagemodelle für Kurzzeitrevisionen des BSP-Wachstums in Deutschland gegeben C	162
6.17 MSFE – Kurzzeitrevisionen – Deutschland	163
6.18 Diebold-Mariano-Test – Kurzzeitrevisionen – Deutschland	163
6.19 MSFE – Kurzzeitrevisionen nach der ersten Revision (C)– Deutschland	164
6.20 Diebold-Mariano-Test – Kurzzeitrevisionen nach der ersten Revision (C)– Deutsch- land	164
A.1 Priorszenarien	178
A.2 Priorspezifikationen	182
A.3 Prior der Präzisionen	185

Kapitel 1

Einleitung

1.1 Gegenstand und Ziel der Arbeit

Das Anliegen dieser Arbeit ist es, grundlegende Einsichten für die Vorhersage und die Modellierung des Konjunkturverlaufs zu gewinnen. Dabei werden neuere Entwicklungen der statistischen und ökonometrischen Literatur auf die Modellierung und Vorhersage der Konjunkturverläufe angewendet. Als Konjunkturvariable wird dabei das Quartalswachstum des realen saisonbereinigten Bruttoinlandsprodukts (BIP) angenommen. Es ist der wichtigste und umfassendste Konjunkturindikator. Der Schwerpunkt der Anwendung liegt dabei auf der Modellierung deutscher Daten. Neben deutschen Daten kommen in einigen Fragestellungen auch Daten aus den USA zum Einsatz um die Ergebnisse vor dem Hintergrund verschiedener Daten zu überprüfen.

Die Arbeit setzt in Kapitel 2 mit der Diskussion der stochastischen Eigenschaften des BIP-Wachstums anhand verschiedener linearer und nicht-linearer univariater Zeitreihenmodelle ein. Es werden eine Vielzahl nicht-linearer Zeitreihenmodelle angepasst, deren ursprüngliche Formulierung in der Regel vor dem Hintergrund von US Daten zu sehen ist: Hamilton (1989), Potter (1995), Pesaran und Potter (1997), Kim et al. (2005) und DeJong et al. (2005). Dabei wird die Fragestellung behandelt, welches der in der US Literatur verwandten Modelle die beste Eignung zur Beschreibung des deutschen Konjunkturverlaufs hat. Die Modelle werden über verschiedene Kriterien miteinander verglichen. Für die Modellgüte wird insbesondere die Marginale Likelihood herangezogen, die einen Vergleich auch zwischen nicht genisteten Modelle ermöglicht, siehe Koop und Potter (1999).

Im Kapitel 2 werden mehrere Methoden zur Überprüfung der Eignung von Modellen diskutiert, die im wesentlichen auf die Likelihood oder die Residuen der Modelle abheben. Kapitel 3 diskutiert eine alternative Methode um die Eignung eines Modelles zur Abbildung des BIP-Wachstums zu überprüfen. Das BIP ist eine Konjunkturvariable und eine BIP-Zeitreihe korrespondiert entsprechend mit dem Konjunkturzyklus. Es schließt sich die Frage an, ob die

verschiedenen Modelle in der Lage sind, den beobachteten Konjunkturzyklus nachzubilden. Diese Form des Modellvergleichs wird für Zeitreihenmodelle von Hess und Iwata (1997) in die Literatur eingeführt. Mit der Entwicklung weiterer Zeitreihenmodelle folgen weitere Arbeiten z.B. von Harding und Pagan (2002), Morley und Piger (2004) oder Engel et al. (2005), die deren Eigenschaften in der Reproduktion von Konjunkturzyklen überprüfen. Alle Autoren befassen sich mit US Daten. Um die Fragestellung zu operationalisieren muss der beobachtete Konjunkturzyklus mit einem reproduzierbaren Verfahren bestimmt werden. Dieses Verfahren kann dann auf simulierte Zeitreihen angewendet werden. Die Wendepunkte des Konjunkturzyklus werden mit Hilfe des deterministischen Bry-Boschan Algorithmus bestimmt. Anhand der so gewonnenen Phasen bzw. Zyklen werden stylisierte Fakten, wie Anzahl, Dauer und Tiefe der Expansionen bzw. Kontraktionen ermittelt. Die verschiedenen Modelle werden als Datenerzeugende Prozesse interpretiert und jeweils eine Vielzahl von Zeitreihen erzeugt und korrespondierender Konjunkturzykluseigenschaften ermittelt. Die somit erzeugten Verteilungen werden dann mit dem beobachteten stylisierten Fakten verglichen. Die vorliegende Untersuchung stellt die erste Überprüfung verschiedener Zeitreihenmodelle dieser Art für deutsche Daten dar.

Eine mögliche beste Charakterisierung des deutschen BIP durch eines der Modelle könnte Erkenntnisse für die ökonomische Modellierung sowie die Formulierung von Vorhersagemodellen mit sich bringen. Die Eigenschaften der nicht-linearen Modelle, die sich der linearen Formulierung als überlegen zeigen, können als Impulse bzw. als Forderungen für entsprechende ökonomische Modelle aufgenommen werden. Die verschiedenen Kriterien zeigen zwar uneinheitliche Ergebnisse. Die Bedeutung von nicht-linearen Modellen ist jedoch insbesondere bei der Nachbildung der Eigenschaften des deutschen Konjunkturzyklus zu erkennen.

Schließlich werden univariate Zeitreihenmodelle im Kontext eines Bruchs in der Volatilität des deutschen BIP-Wachstums in Kapitel 4 diskutiert. Für die USA gibt es eine umfassende Literatur, die eine Reduktion der Volatilität in Form eines Bruchs in das Jahr 1984 datiert, siehe u.a. Kim und Nelson (1999a) oder McConell und Perez-Quiros (2000). Für Deutschland gibt es unterschiedliche Ergebnisse, vgl. Mills und Wang (2003), Buch et al. (2004) und Fritsche und Kuzin (2005a). Kapitel 4 greift daher diese Fragestellung auf, wobei die Einsicht von Kim und Nelson (1999a), dass die Mittelwertspezifikation erheblichen Einfluss auf die Analyse bzw. Datierung einer möglichen Volatilitätsreduktion haben kann, berücksichtigt wird. Entsprechend werden einige der in Kapitel 2 vorgestellten Modelle zusammen mit einem Bruch in der bedingten Varianz angepasst. Es wird eine Bayesianische Analyse durchgeführt, da diese eine bessere Datierung eines möglichen Bruchs bietet als frequentistische Verfahren, was angesichts der bisherigen Uneinheitlichkeit der Datierung des Volatilitätsbruchs in Deutschland von besonderem Interesse ist. Schließlich werden die Komponenten des BIP-Wachstums analysiert um mögliche Ursachen für die Volatilitätsreduktion in Deutschland zu bestimmen.

In der Vorhersage der Konjunktur und des Konjunkturzyklus spielen Frühindikatoren eine

bedeutende Rolle. Kapitel 5 geht auf die Rolle von Frühindikatoren ein. An die Diskussion verschiedener Vorhersage- und Frühindikatormodelle schließt sich die Frage der strukturellen Stabilität der Vorlaufeigenschaften einzelner Frühindikatoren an, die exemplarisch anhand des Frühindikators Zinsdifferenz diskutiert wird. In Kapitel 5 wird dabei insbesondere die Hypothese untersucht, dass die Vorlaufeigenschaften der Zinsdifferenz von der Geldpolitik determiniert werden. Chauvet und Potter (2002), Estrella et al. (2003) oder Venetis et al. (2003) finden in ihren Untersuchungen Strukturbrüche im Vorlaufverhalten der Zinsdifferenz zu realwirtschaftlichen Größen wie BIP oder Industrieproduktion. Estrella (2005) gibt in einem ökonomischen Modell eine mögliche Erklärung für das Vorlaufverhalten der Zinsdifferenz. Im Modell werden die Vorlaufeigenschaften durch die Geldpolitik bestimmt. Dieser Zusammenhang wird von Estrella empirisch mit der Schätzung linearer Modelle über verschiedene Zeiträume überprüft. Die vorliegende Arbeit greift die Zeitvarianz des Vorlaufverhaltens der Zinsdifferenz auf, indem diese explizit in Form eines zeitvariierenden Koeffizienten modelliert wird. Dabei wird ein Markov-Switching Prozess für den Koeffizienten unterstellt. Um die Hypothese mit der Determination durch die Geldpolitik zu überprüfen wird ein gemeinsames Markov-Switching-Modell für das Vorhersagemodell und die Geldpolitik unterstellt. Der Zusammenhang zwischen Geldpolitik und Vorlaufeigenschaften der Zinsdifferenz, der bei Estrella (2005) ad hoc überprüft wird, wird in dieser Arbeit explizit modelliert und somit direkt überprüfbar.

Bei der Vorhersage des BIP-Wachstums am aktuellen Rand ist die besondere Eigenschaft der Daten, wie sie von den statistischen Ämtern berichtet werden, zu berücksichtigen. Es handelt sich bei diesen um auf Stichproben basierende Schätzungen des tatsächlichen Geschehens. Wegen des Prozesses der Datenerhebung gibt es einen zeitlichen Verzug des Berichts der Daten im Vergleich zu ihrer Entstehung. Sofern erste Erkenntnisse vorliegen, in der Regel ein bis zwei Monate nach dem zu berichtenden Quartal, werden die ersten Schätzungen des BIP-Wachstums veröffentlicht. Der Prozess der Datenerhebung ist jedoch noch nicht abgeschlossen und neue Informationen führen zu Veränderungen (Verbesserungen) der Schätzungen. Dieser Prozess der Datenrevision kann mehrere Jahre in Anspruch nehmen, bis sich die BIP-Zahlen nicht mehr ändern. Die ersten Veröffentlichungen der Daten können zum Teil erheblich von den späteren Werten abweichen und nehmen Einfluss auf die Ergebnisse makroökonomischer Modelle und auf Vorhersagen.

Wegen der Verzögerung zwischen Entstehung und erster Veröffentlichung der BIP-Zahlen entstand in den letzten Jahren eine breite Literatur zum Thema "Now- and Backcasting" des BIP, die höher frequente und schneller verfügbare Variablen nutzt, um die aktuelle Entwicklung vor den statistischen Ämtern abzuschätzen, siehe z.B. Evans (2005) oder Mitchell et al. (2005). Diese Arbeit nimmt in Kapitel 6 diese Ansätze auf und nutzt sie zur Vorhersage von Datenrevisionen mit der Überlegung, dass nicht alle verfügbare Information in die erste Datenrevision einfließt. Bestehende Arbeiten zur Erklärung und Prognose von Datenrevisionen des BIP, wie Faust et al. (2005) oder Fixler und Grimm (2006), verwenden nur Regressoren gleicher Frequenz wie das BIP und vernachlässigen dadurch eventuell wichtige Informationen, die am aktuellen Rand

verfügbar sind. Die Ergebnisse für die USA sprechen dafür die Techniken, die im “Nowcasting” Anwendung finden, auch für die Prognose von Datenrevisionen zu nutzen.

1.2 Definition von Konjunktur und Konjunkturzyklus

Im weitesten Sinne wird mit Konjunktur die realwirtschaftliche Entwicklung als Ganzes bezeichnet. Die Konjunktur ist nicht direkt beobachtbar. Konjunkturindikatoren, also verschiedene makroökonomische Variablen, die von der Konjunktur abhängen, dienen dazu Aussagen über die Konjunktur, Konjunktorentwicklung und Konjunkturschwankungen treffen zu können. Für Konjunkturschwankungen wird oft der Begriff “Konjunkturzyklus” verwendet. Der Begriff “Konjunkturzyklus” erweckt die Assoziation, dass sich Expansionen und Kontraktionen des realwirtschaftlichen Geschehens in Form einer Schwingung mit fester Periodizität abwechseln. Diese Vorstellung entstammt den frühen Arbeiten zur Konjunktur und zum Konjunkturzyklus in der zweiten Hälfte des 19. und der ersten Hälfte des 20. Jahrhunderts. In der zweiten Hälfte des 19. Jahrhunderts finden konjunkturelle Schwankungen in der ökonomischen Literatur ihren Niederschlag, zum Beispiel spricht Marx (1867) von den wiederkehrenden Krisen der Industrie. Juglar (1863) beschreibt den Konjunkturzyklus als periodisches Auf und Ab von Produktion, Nachfrage und Preisen. Die Dauer eines Zyklus liegt laut Juglar zwischen 7 und 11 Jahren. Ebenfalls einen Zyklus fester Periodizität unterstellt Jevons (1884), der als Ursache das Auftreten von Sonnenflecken annimmt, die entsprechend Einfluss auf das Klima und die Ernte nehmen. Aus den Beobachtungen finanzieller Variablen der USA und des UK der Jahre 1890 bis 1920 schlussfolgert Kitchin (1923) eine Zyklusdauer von $3\frac{1}{2}$ Jahren. Kuznets (1930a,1930b) arbeitet auf Grundlage von US-Daten zwischen 1840 und 1914 eine Länge des Konjunkturzyklus von 15 bis 20 Jahren heraus, weist aber auch daraufhin, dass die Vorstellung einer festen Periodizität zu kritisieren ist. Den kurz- und mittelfristigen Konjunkturzyklen stellt Kondratieff (1926) die Vorstellung gegenüber, dass diese von langfristigeren Zyklen überlagert werden, die von bedeutenden technischen Innovationen hervorgerufen werden.

Die Literatur über die Periodizität der Konjunkturzyklen reagiert jeweils auf die mit der Zeit zunehmenden Konjunkturdaten. Um das Fehlschlagen einzelner Zykluskonzepte zu beheben, wurde versucht die tatsächlich beobachteten Zeitreihen als eine Mischung mehrerer Zykluskonzepte zu erklären.¹ Bereits in den 20er und 30er Jahren des 20. Jahrhunderts wurden die Zyklen fester Periodizität kritisiert (siehe z.B. Kuznets [1930a]). Die Definition des Konjunkturzyklus von Burns und Mitchell (1946), die in modifizierter Form auch aktuell vom National Bureau of Economic Research (NBER) verwendet wird, greift diese Kritik auf und formuliert vielmehr, dass die Dauer der Konjunkturzyklen variiert:

¹Vgl. z.B. Schumpeter (1939), der auch daraufhinweist, dass die Identifikation von mehrfach überlagerten Zyklen problematisch ist.

Business cycles are a type of fluctuation found in the aggregate economic activity of nations that organize their work mainly in business enterprises: a cycle consists of expansions occurring at about the same time in many economic activities, followed by similarly general recessions, contractions, and revivals which merge into the expansion phase of the next cycle; this sequence of changes is recurrent but not periodic; in duration business cycles vary from more than one year to ten or twelve years; they are not divisible into shorter cycles of similar character with amplitude approximating their own.

Der Konjunkturzyklus ist definiert als Abfolge von Expansionen und Kontraktionen des realwirtschaftlichen Geschehens, die eine Vielzahl von Bereichen der Ökonomie betreffen.² Dieser Definition folgend kann der Konjunkturzyklus als Historie der Wechsellpunkte von Expansionen zu Kontraktionen aufgefasst werden. Für die USA besteht mit NBER eine Institution, die die Wechsellpunkte festlegt. NBER berücksichtigt bei dieser Arbeit insbesondere vier monatlich erhobene Indikatoren. Das BIP, der umfassendste Konjunkturindikator, wird nur quartalsweise erhoben.

Viele das realwirtschaftliche Geschehen beeinflussende Größen, zum Beispiel Faktorausstattung oder Demographie, sind nur geringen kurzfristigen Schwankungen ausgesetzt und entwickeln sich eher langfristig. Die realwirtschaftliche Entwicklung wird daher oft in kurzfristige konjunkturelle Schwankungen und langfristiges Wachstum unterteilt.³ Der gedanklichen Trennung in Konjunktur und Wachstum entspricht auf der empirischen Seite die Literatur zur Trendbereinigung bzw. zu entsprechenden Filtern. Canova (1998) bietet einen Überblick über verschiedene Trendbereinigungsverfahren, die für makroökonomische Zeitreihen eine Rolle spielen, und thematisiert, dass das Trendbereinigungsverfahren Einfluss auf die Eigenschaften der resultierenden Konjunkturkomponente und die Datierung der Wechsellpunkte der Konjunktur hat.⁴ Eine eindeutige Trennung von Trend und Konjunktur scheint vor diesem Hintergrund problematisch und für einige Adressaten konjunktureller Daten, die wie zum Beispiel die Schätzer von Steuereinnahmen an der Gesamtentwicklung interessiert sind, nur bedingt sinnvoll, so dass in dieser Arbeit das Augenmerk auf die direkte Modellierung und Vorhersage von Konjunkturindikatoren bzw. deren ersten Differenzen gesetzt wird. Verschiedene Bestandteile der Daten wie Trend und

²Erklärungen für das Auftreten von Konjunkturphänomenen bzw. Konjunkturtheorien sind nicht Gegenstand dieser Arbeit. Einzelne Aspekte werden bestimmte ökonomische Theorien tangieren bzw. auch Implikationen für Konjunkturtheorien mit sich bringen, wie einige der in Kapitel 2 besprochenen Modelle oder die Erklärung für das Verhalten des Frühindikators Zinsdifferenz. Diese Arbeit ist jedoch in keiner Weise als Stellungnahme zu interpretieren, die einer bestimmten Konjunkturtheorie den Vorzug gibt. Eine Zusammenschau verschiedener Konjunkturmodelle findet sich in Heubes (1991) oder Assenmacher (1998). Eine umfassendere Darstellung der Real-Business-Cycle-Theorie und Keynesianischer Ansätze findet sich z.B. in Romer (2001).

³Vgl. z.B. Lucas (1981).

⁴Zu den populärsten Trendbereinigungsverfahren zählen die Filter von Hodrick und Prescott (1997) sowie Baxter und King (1999).

Konjunktur werden also a priori nicht unterschieden. In einigen Modellen, die insbesondere in den Kapiteln 2 und 3 eine Rolle spielen werden, werden vielmehr Trendbewegungen in der Darstellung der Wachstumsraten des BIP direkt berücksichtigt. Ferner weisen Harding und Pagan (2002) daraufhin, dass Burns und Mitchell in ihrer grundlegende Arbeit keine trendbereinigten Daten verwendet haben. Harding und Pagan argumentieren daher für die direkte Verwendung des BIP bzw. seiner Wachstumsraten für die Konjunkturanalyse. Diese Arbeit beschäftigt sich folglich mit den Fragen, die im Zusammenhang mit der Modellierung, Vorhersage und Revision des Konjunkturindikators BIP bzw. seiner Wachstumsraten auftreten.

Das Bruttoinlandsprodukt (BIP) bzw. das Bruttosozialprodukt (BSP) ist die umfassendste und daher wichtigste Konjunkturvariable,⁵ da sie die Aktivitäten aller Zweige der Ökonomie zusammenfasst, was bereits in Burns und Mitchell (1946) seinen Niederschlag fand:

Aggregate [economic] activity can be given a definite meaning and made conceptually measurable by identifying it with gross national product.

Burns und Mitchell (1946) sowie viele nachfolgende Autoren und Institutionen berücksichtigen in ihrer Arbeit eine Vielzahl anderer Indikatoren zur Bestimmung der Konjunktur bzw. Datierung von Konjunkturzyklen. Dieser Umstand lässt sich insbesondere über die niedrige (quartalsweise) Frequenz und teilweise schlechte Qualität bzw. der Zeitverzögerung der Veröffentlichungen der BIP Daten am aktuellen Rand erklären. Vor diesem Hintergrund ist in den letzten Jahren zum einen eine breite Literatur zum Thema monatlicher Repräsentationen des BIP⁶ und zum anderen die bereits erwähnte Diskussion zum Thema “Nowcasting” entstanden. Letztlich ist das Missverhältnis zwischen der eigentlichen Relevanz des Konjunkturindikators BIP und der reduzierten Qualität seiner Daten insbesondere am aktuellen Rand der Anlass in dieser Arbeit die Entwicklungen zum Thema “Nowcasting” mit der Frage der Vorhersagbarkeit von Datenrevisionen zu verbinden.

1.3 Aufbau der Arbeit

Die Arbeit setzt in Kapitel 2 mit der Vorstellung verschiedener Zeitreihenmodelle ein, die überwiegend im Zusammenhang mit der Analyse des BIP-Wachstums der USA formuliert werden. Diese Zeitreihenmodelle werden auf die Quartalswachstumsraten des deutschen BIP zwischen 1971 und 2006 angewendet. Die Anpassungsgüte der Modelle wird in-sample über die Marginale Likelihood diskutiert, deren Berechnung und die korrespondierenden Ergebnisse für die einzelnen Modelle werden in Abschnitt 2.3 dargestellt. Neben der Diskussion der in-sample Ergebnisse

⁵BIP und BSP unterscheiden sich in der Abgrenzung der nationalen Wirtschaftsleistung. Das BIP folgt dem Inlandskonzept während das BSP entsprechend des Inländerkonzepts ermittelt wird. Seit den 90er Jahren ist das BIP gebräuchlicher.

⁶Vgl. unter anderen Mariano und Murasawa (2003), Nunes (2005) oder Proietti und Moauro (2006).

geht es um die Fragestellung, ob sich die univariaten Modelle zur Vorhersage zukünftiger Konjunkturentwicklungen oder zur Abschätzung der Prognoseunsicherheit eignen. In Abschnitt 2.4 werden die Methoden zur Evaluation von Punkt- und Intervallprognosen dargestellt und auf die Prognosen für das deutsche BIP-Wachstum der verschiedenen Modelle angewendet.

Kapitel 3 setzt mit der Diskussion von Konjunkturzykluseigenschaften ein und referiert die Literatur zu US-Daten, die die Nachbildbarkeit von Konjunkturzykluseigenschaften als Modellkriterium verwenden. In Abschnitt 3.2 werden die im Zusammenhang mit der Entstehung der Modellierung des BIP-Wachstums diskutierten Asymmetrien des Konjunkturzyklus erläutert. Sie werden im Folgenden auch zu den Konjunkturzykluseigenschaften gezählt, an deren Reproduktion sich die Modelle messen lassen. Schließlich wird der Bry-Boschan-Algorithmus zur Datierung von Wechsellpunkten der Konjunktur eingeführt und in Abschnitt 3.4 werden die Simulationsergebnisse der verschiedenen Modelle im Vergleich mit den Konjunkturzykluseigenschaften, die aus den deutschen BIP resultieren, besprochen. Abschnitt 3.5 liefert eine zusammenfassende Diskussion zur Bedeutung von Nicht-Linearitäten für das deutsche BIP.

Kapitel 4 bietet eine Analyse einer möglichen Volatilitätsreduktion des deutschen BIP-Wachstums in Hinblick auf die Fragen, ob es eine Reduktion gegeben hat, wie diese Reduktion zu datieren und zu charakterisieren ist sowie auf welche Ursachen sie zurückgeführt werden kann. Abschnitt 4.2 beantwortet dabei die Frage “Ob?” und “Wann?” und diskutiert vor dem Hintergrund verschiedener Zeitreihenmodelle die Charakterisierung der Volatilitätsreduktion. In Abschnitt 4.3 werden dann mögliche Ursachen anhand der Analyse der Komponente des BIP untersucht.

Die Frage nach der Vorhersagbarkeit der Konjunktur wird in Kapitel 5 wieder aufgegriffen. In Abschnitt 5.1 wird die Rolle, die Frühindikatoren an dieser Stelle haben, besprochen. Am Beispiel des Frühindikators Zinsdifferenz wird das Problem zeitvarierender Vorlaufeigenschaften in Abschnitt 5.2 für den deutschen wie den US Fall diskutiert. Schließlich wird in Abschnitt 5.3 ein gemeinsames Markov-Switching-Modell für die Vorlaufeigenschaften der Zinsdifferenz und die Geldpolitik angelehnt an ökonomische Theorien zur Begründung der Vorlaufeigenschaften entwickelt. Die empirische Überprüfung des Modells im gleichen Abschnitt dient letztlich der Analyse der ökonomischen Signifikanz der Zinsdifferenz als Frühindikator.

In Kapitel 6 werden Ansätze aus der Diskussion über die Prognose des BIP genutzt, um Vorhersagemodelle für Datenrevisionen des BIP zu erstellen. Nachdem Abschnitt 6.1 die grundlegenden Begriffe einführt, werden in Abschnitt 6.2 Methoden zur Berücksichtigung von höher frequenten Regressoren diskutiert und schließlich darauf basierend in Abschnitt 6.3 Vorhersagemodelle für Revisionen des BIP-Wachstums formuliert. In Abschnitt 6.3 werden die Modelle auf US Daten und deutsche Daten zu Revisionen des BSP-Wachstums angewendet. Kapitel 7 beschließt die Arbeit.

Kapitel 2

Zeitreihenmodelle des BIP-Wachstums

Im Rahmen der Diskussion des Trendverhaltens des BIP fanden insbesondere ARMA-Modelle für das BIP-Wachstum Anwendung, siehe Nelson und Plosser (1982) oder Campbell und Mankiw (1987). ARMA-Modelle bieten eine Darstellung des BIP-Wachstums in reduzierter Form, die eine Vielzahl von Symmetrieannahmen mit sich bringt. So werden Schocks in verschiedenen Konjunkturphasen identisch verarbeitet und Übergänge von Expansionen zu Rezessionen werden mit der gleichen Dynamik modelliert wie umgekehrte Übergänge. Insbesondere im Bezug auf das BIP der USA existiert eine intensive Diskussion über verschiedene Formen der Asymmetrien im Konjunkturverlauf, vgl. Abschnitt 3.2. Die den ARMA-Modellen inhärenten Symmetrieannahmen werden aus diesem Blickwinkel kritisiert. Im Zusammenhang mit der Diskussion von Asymmetrien ist eine Vielzahl nicht-linearer Zeitreihenmodelle auf das BIP der USA angewendet oder für diese Zeitreihe entwickelt worden. Eine Auswahl dieser Modelle wird hier vorgestellt und, teilweise in Adaption, auf das deutsche BIP-Wachstum angewendet. Es handelt sich dabei um die Modelle von Hamilton (1989), Potter (1995), Pesaran und Potter (1997), Kim et al. (2005) sowie DeJong et al. (2005), die sämtlich etablierte Modelle des US BIP-Wachstums sind. In diesem Kapitel werden die Anpassungsgüte (In-Sample-Fit) und Prognosegüte (Out-of-Sample-Fit) dieser Modelle diskutiert. Ferner geht das folgende Kapitel 3 auf die Frage ein, welches der Zeitreihenmodelle den deutschen Konjunkturzyklus am besten reproduzieren kann. Zur Analyse der Anpassungs- und Prognosegüte kommen an dieser Stelle sowohl frequentistische wie Bayesianische Methoden zum Einsatz. Die Vorteile der Bayesianischen Methode insbesondere im Zusammenhang mit nicht-linearen Modellen wird in Abschnitt 2.5 erläutert. Ein Nachteil Bayesianischer Methoden ist die Abhängigkeit von a priori Annahmen. Daher werden auch und insbesondere für die Prognosen frequentistische Methoden verwendet.

Die Beschäftigung mit nicht-linearen Zeitreihenmodellen bzw. das Auffinden von Nicht-Lineari-

täten ist aus mehreren Perspektiven erstrebenswert. Zum einen ist es sinnvoll nicht-lineare Modelle als mögliche Prognosemodelle für das deutsche BIP-Wachstum zu berücksichtigen. In dieser Hinsicht wird in diesem Kapitel überprüft, ob sich nicht-lineare Modelle als überlegenen Prognosemodelle anbieten. Zum anderen kann das Auffinden von Nicht-Linearitäten einen wichtigen Hinweis für andere ökonomische und ökonometrische Modelle liefern. Kiani und Bidarkota (2004) weisen daraufhin, dass Nicht-Linearitäten bedeuten können, dass Schocks nicht symmetrisch propagiert werden und somit die Verwendung von VAR-Modellen, die diese Symmetrie annehmen, zweifelhaft ist. In diesem Sinne ist das Auffinden von Nicht-Linearitäten mit entsprechenden Anforderungen an die ökonomische Modellierung verbunden.

2.1 Modelldarstellung und Maximum Likelihood Schätzung

2.1.1 Lineare Modelle

ARMA-Modelle spielen wie erwähnt eine große Rolle in der Modellierung des BIP-Wachstums. Sie dienen an dieser Stelle als Benchmark für die nicht-linearen Modelle. Ein ARMA(k, m)-Modell kann wie folgt repräsentiert werden:

$$y_t = \mu + \sum_{\ell=1}^k \phi_{\ell} y_{t-\ell} + \sum_{i=0}^m \psi_i \epsilon_{t-i}, \quad \epsilon_t \sim \mathcal{N}(0, \sigma^2), \quad (2.1)$$

wobei y_t die realen saisonbereinigten Quartalswachstumsraten des BIP und ϵ_t iid Innovationen repräsentieren. Durch ARMA-Modelle kann die Persistenz von Schocks abgebildet werden.¹ Eine kritische Annahme, die mit ARMA-Modellen einhergeht, ist die Symmetrie des Modells: z.B. werden Schocks annahmegemäß in Kontraktionen genauso wie in Expansionen verarbeitet.

Für die Parameter des ARMA-Modells wird eine konditionale Maximum-Likelihood Schätzung (ML) verwendet. Wird auf die ersten k Beobachtungen bedingt, lässt sich die Likelihood allgemein wie folgt darstellen:

$$L(\Theta; Y) = \prod_{t=1}^T f(y_t | y_{t-1}, \dots, y_{t-k}, \mu, \phi, \psi, \sigma^2). \quad (2.2)$$

Im Falle eines reinen AR-Modells mit normalverteilten Fehlern ist

$$f(y_t | y_{t-1}, \dots, y_{t-k}, \mu, \phi, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left\{ -0.5 \frac{(y_t - \mu - \sum_{\ell=1}^k \phi_{\ell} y_{t-\ell})^2}{\sigma^2} \right\}. \quad (2.3)$$

Die ML-Schätzung der konditionalen Likelihood entspricht in diesem Fall einer Kleinst-Quadrate Schätzung. Ein ARMA-Modell wiederum kann als Zustandsraummodell dargestellt werden, so

¹Die im Rahmen der ARMA-Modelle gefundene Persistenz in den US Daten hat weitreichenden Einfluss auf die theoretische wie empirische Literatur genommen.

dass zur Berechnung der konditionalen Likelihood der Kalman-Filter verwendet werden kann.² Bei der Anwendung auf die deutschen Daten wird die Anzahl der Parameter des ARMA-Modells (Anzahl der Verzögerten) mit Hilfe der Informationskriterien AIC und BIC auf vier AR-Koeffizienten bestimmt. MA-Terme bringen keine Verbesserung. Vier Verzögerte werden im Wesentlichen auch für die folgenden nicht-linearen Modelle beibehalten.

2.1.2 Markov-Switching-Modelle

Eines der ersten nicht-linearen Modelle für das BIP-Wachstum wird von Hamilton (1989) vorgeschlagen. In Markov-Switching Modellen (MS-Modellen) entstammen die Wachstumsraten nicht einem einzigen linearen Prozess, vielmehr wird eine diskrete Anzahl linearer Prozesse unterstellt sowie eine Zustandsvariable s_t , die eine entsprechende Anzahl diskreter Ausprägungen annehmen kann und angibt aus welchem der Prozesse die laufende Wachstumsrate entstammt. Die Wachstumsraten haben die folgende Repräsentation:

$$y_t = \mu_{s_t} + \sum_{\ell=1}^k \phi_{s_t, \ell} y_{t-\ell} + \epsilon_t, \quad \epsilon_t \sim \mathcal{N}(0, \sigma_{s_t}^2). \quad (2.4)$$

In dieser Formulierung variieren der Achsenabschnitt μ_{s_t} , die autoregressiven Parameter $\phi_{s_t, \ell}$ und die Fehlervarianz $\sigma_{s_t}^2$. Die Zustandsabhängigkeit kann allerdings auch auf einzelne Parameter beschränkt werden. Variiert nur der Achsenabschnitt spricht man vom MSI-Modell (vom engl. "intercept"), bei den autoregressiven Parametern vom MSA und bei der Varianz vom MSH (Heteroskedastie), vgl. Krolzig (1997).

In der ursprünglichen Formulierung von Hamilton (1989), dem MSM, ist der Mittelwert zustandsabhängig:

$$y_t = \mu_{s_t} + \sum_{\ell=1}^k \phi_{\ell} (y_{t-\ell} - \mu_{s_{t-\ell}}) + \epsilon_t. \quad (2.5)$$

In allen Fällen ist die Zustandsvariable s_t unbeobachtbar und folgt einem Markov-Prozess. Die Wahrscheinlichkeit, gegeben in Zustand j zu sein, in den Zustand i zu wechseln ist entsprechend p_{ij} :

$$P(s_{t+1} = i | s_t = j) = p_{ij}. \quad (2.6)$$

Inferenz über die unbeobachteten Zustände ist über den Hamilton-Filter möglich, der in Appendix A.1 erläutert wird.

Die Interpretation insbesondere des MSM-Modells mit zwei Zuständen ist intuitiv. Phasen hohen und niedrigen Wachstums wechseln sich ab. Hamilton (1989) findet für die USA, dass die Zustände in etwa den Phasen, die durch den NBER-Zyklus definiert werden, entsprechen.

²Vgl. Kim und Nelson (1999a).

Markov-Switching Modelle werden daher auch in der Datierung und Vorhersage von Konjunkturwechsellpunkten eingesetzt.³ Hamilton weist selbst daraufhin, dass die Schätzung eines MS-Modells mit zwei Zustände nicht zu dem Ergebnis führen muss, dass die Zustände als Konjunkturphasen zu interpretieren sind, sondern die Zustände auch anderen Eigenschaften der Zeitreihe entsprechen können. Hamilton erwähnt die Möglichkeit, dass unterschiedliche Trendwachstumsraten existieren und im MS-Modell identifiziert werden könnten, siehe Hamilton (1989), S. 359. Vor dem Hintergrund der Asymmetrien des Konjunkturzyklus werden in der Literatur zu US Daten MSM-Modelle mit drei Zuständen diskutiert, siehe z.B. McQueen und Thorley (1993). Der dritte Zustand wird mit der Beobachtung motiviert, dass direkt nach Kontraktionen Phasen relativ hohen Wachstums folgen, deren Wachstumsraten höher sind als in der Folgezeit einer Expansion.

In dieser Arbeit kommt das MSI-Modell für die deutschen Daten zur Anwendung. Die Ergebnisse des Hamilton-Modells (MSM) unterscheiden sich kaum von denen des MSI-Modells und werden daher an dieser Stelle nicht berichtet. Ferner wird der Fall einer zeitgleichen Variation von Interzept und Varianz (MSIH) berücksichtigt. Für deutsche Daten schlagen Fritsche und Kuzin (2005a) außerdem die Verwendung von zustandsabhängigen Persistenzen vor. Folglich kommt auch das MSA-Modell zur Anwendung, welches ebenfalls mit einer heteroskedastischen Komponente erweitert wird (MSAH).

Die Schätzung von Markov-Switching-Modellen ist mit der Maximum-Likelihood-Methode möglich. Die Likelihood, wie sie in Gleichung 2.2 aufgestellt ist, ist jedoch nicht direkt berechenbar. Gegeben die Zustandsvariable s_t entspricht das MS-Modell allerdings einem linearen Modell bzw. einer der Anzahl der Regime entsprechenden Anzahl linearer Modelle. Unterstellt man eine Normalverteilung für die Fehler ϵ_t , ist die auf die Zustandsvariablen bedingte Verteilung von y_t gegeben durch:

$$f(y_t | \tilde{s}_t, y_{t-1}, \dots, y_{t-k}, \Theta) = \frac{1}{\sqrt{2\pi}\sigma_{s_t}} \exp \left\{ -0.5 \frac{(y_t - \mu_{s_t} - \sum_{\ell=1}^k \phi_{s_t, \ell} y_{t-\ell})^2}{\sigma_{s_t}^2} \right\}, \quad (2.7)$$

wobei \tilde{s}_t die Ausprägungen der Zustandsvariablen bis zum Zeitpunkt t darstellt ($\tilde{s}_t = \{s_i\}_{i=1}^t$) und y_{t-1}, \dots, y_{t-k} die Verzögerten der Abhängigen. Der Term $f(y_t | y_{t-1}, \dots, y_{t-k}, \Theta)$ ist wie bereits erwähnt nicht direkt darstellbar, da die Zustandsvariablen $\{s_t\}_{t=1}^T$ erst aus der Gleichung 2.7 “herausintegriert” werden müssen. Die dazugehörigen Zustandswahrscheinlichkeiten können mit Hilfe des Hamilton-Filters ermittelt und somit die Faktoren der konditionalen Likelihoodfunktion aus Gleichung 2.2 bestimmt werden. Diese kann dann mit numerischen Verfahren über die entsprechenden Parameter maximiert werden.⁴ Neben den üblichen Verfahren bietet

³Beispiele sind Boldin (1994) und Chauvet (1998).

⁴Der Hamilton-Filter basiert auf Hamilton (1989). Für Zustandsraummodelle, deren Bewegungsgleichung einem Markov-Switching Prozess unterliegt, hat Kim (1994) eine entsprechende Modifikation vorgeschlagen. Dort wird auch ein vereinfachter Glätter vorgeschlagen, der im Rahmen des EM-Algorithmus im Erwartungsschritt verwendet werden kann. Der Glätter wird in Anhang A.1 erläutert.

sich der EM-Algorithmus für die ML-Schätzung eines Markov-Switching-Modells an. Der EM-Algorithmus wird seit der Arbeit von Dempster et al. (1977) als Methode in der empirischen Wirtschaftsforschung angewendet und wurde von Hamilton (1990) für das Markov-Switching Problem formuliert.⁵ Er hat relativ gute Konvergenzeigenschaften. Die Standardfehler der Parameterschätzer müssen allerdings zusätzlich ermittelt werden, während diese z.B. bei Gradientenverfahren wie dem Gauß-Newton-Verfahren bei der Optimierung mit berechnet werden. Bei der ML-Schätzung kann wegen möglicher Multimodalität der Likelihoodfunktion von Mischungsverteilungen unabhängig vom Lösungsalgorithmus das Problem auftreten, ein lokales und kein globales Maximum zu ermitteln. Daher wird der Algorithmus für mehrere Startwerte wiederholt und das globale Maximum als Supremum der verschiedenen Versuche ermittelt.

2.1.3 Bounce-Back-Modell

Das Bounce-Back-Modell von Kim et al. (2005) stellt eine Erweiterung des Hamilton-Modells dar. Die Motivation für den Bounce-Back-Effekt korrespondiert mit der Motivation eines dritten Zustandes des MSM-Modells in McQueen und Thorley (1993). Das asymmetrische Verhalten nach Expansionen und Kontraktionen soll explizit modelliert werden. In der Formulierung des Bounce-Back werden die Ansätze von Beaudry und Koop (1993) mit dem MS-Modell verbunden.⁶ Die Neuerung im Vergleich zum Hamilton-Modell ist, dass mit Beginn eines kontraktiven Regimes, ein zusätzlicher Regressor aufgebaut wird, der von der Tiefe der Kontraktion bzw. Rezession abhängt.

Das Modell entspricht weitgehend dem bereits beschriebenen Markov-Switching-Modell. Abweichend von Kim et al. (2005) wird an dieser Stelle das Bounce-Back-Modell auf Grundlage des MSI-Modells und nicht des MSM-Modells verwendet. Die Zustandsvariable s_t nehme den Wert 1 für expansive Regime und den Wert 0 für kontraktive an. Das Bounce-Back-Modell, wie es in dieser Arbeit verwendet wird, lässt sich dann wie folgt formulieren:

$$y_t = \mu_{s_t} + \sum_{\ell=1}^k \phi_{\ell} y_{t-\ell} + \gamma \sum_{j=1}^m (1 - s_{t-j}) y_{t-j} + \epsilon_t, \quad \epsilon_t \sim \mathcal{N}(0, \sigma^2). \quad (2.8)$$

Wenn γ einen negativen Wert annimmt, tritt schon während der Rezession und bis zu m Quartale nach der Rezession ein positiver Effekt ein, der das Wachstum erhöht. Die ML-Schätzung des Bounce-Back-Modells ist analog zum MS-Modell mit Hilfe des Hamilton-Filters möglich.

2.1.4 SETAR-Modell

Potter (1995) schlägt die Verwendung des Self-Exciting Threshold Autoregression-Modells (SETAR) vor, um das BSP-Wachstum der USA zu modellieren. Das Modell soll die Asymmetrie,

⁵Hartley (1958) hat bereits den EM-Algorithmus verwandt, jedoch nicht seine Konvergenz bewiesen.

⁶Die Arbeit von Beaudry und Koop (1993) wird im Rahmen des Floor-and-Ceiling-Modells diskutiert.

mit der Schocks in verschiedenen Phasen des Konjunkturzyklus verarbeitet werden, abbilden.

Analog zum Markov-Switching Modell werden mehrere lineare Prozesse unterstellt, die zusammen den datenerzeugenden Prozess bilden. Im Gegensatz zum Markov-Switching ist die Variable (Schwellenvariable), die den Zustand bestimmt, beobachtbar. Im SETAR-Modell wird die eigene Vergangenheit des Prozesses als Schwellenvariable eingesetzt (daher “Self-Exciting”). Das SETAR-Modell mit zwei Zuständen kann wie folgt dargestellt werden:

$$y_t = \begin{cases} \mu_1 + \sum_{\ell=1}^k \phi_{1,\ell} y_{t-\ell} + \sigma_1 \eta_t, & \text{falls } y_{t-q} < r, \\ \mu_2 + \sum_{\ell=1}^k \phi_{2,\ell} y_{t-\ell} + \sigma_2 \eta_t & \text{sonst,} \end{cases} \quad (2.9)$$

wobei $\eta_t \sim N(0, 1)$. Der Parameter r ist der Schwellenwert, dessen Überschreitung durch die Schwellenvariable y_{t-q} zum Regimewechsel führt.

Analog zum MS-Modell entspricht das SETAR-Modell für gegebene Zustände bzw. für einen gegebene Schwellenwert einem linearen Modell. Der Unterschied zum MS-Modell ist, dass der Parameter r direkt mit der Zustandsvariable korrespondiert und kein Parameter eines latenten Prozess ist, wie es bei den Übergangswahrscheinlichkeiten im MS-Modell der Fall ist. Die Likelihood für gegebene Parameter ist daher leicht zu formulieren:

$$L(\Theta; Y) = \prod_{y_{t-q} < r} \frac{1}{\sqrt{2\pi}\sigma_1} \exp \left\{ -.5 \frac{(y_t - \mu_1 - \sum_{\ell=1}^k \phi_{1,\ell} y_{t-\ell})^2}{\sigma_1^2} \right\} \cdot \prod_{y_{t-q} \geq r} \frac{1}{\sqrt{2\pi}\sigma_2} \exp \left\{ -.5 \frac{(y_t - \mu_2 - \sum_{\ell=1}^k \phi_{2,\ell} y_{t-\ell})^2}{\sigma_2^2} \right\}. \quad (2.10)$$

Die Maximierung über den Parameter r ist jedoch nicht trivial. Da verschiedene Werte des Parameters r zwischen zwei geordneten Ausprägungen der Schwellenvariable ($y_{(i)} < r < y_{(i+1)}$) zu gleichen Werten der Likelihood führen und an der Stelle $r = y_{(i+1)}$ ein Sprung auftritt, ist die Likelihood nicht differenzierbar in r . Für den Parameter r wird daher eine Gittersuche (“grid search”) durchgeführt; die Likelihood wird also für alle sinnvollen Werte von r für die anderen Parameter maximiert, was mit Hilfe der KQ-Methode durchgeführt werden kann, und anschließend der maximale Wert und die dazugehörigen Parameter der konzentrierten Likelihoods ausgewählt.

2.1.5 Floor-Ceiling-Modell

Die bereits im Zusammenhang mit dem dritten Zustand des MSM-Modells sowie der Formulierung des Bounce-Back Modells diskutierte Beobachtung, dass für US-Daten nach Rezessionen ein zusätzlich verstärktes Wachstum existiert, wurde zuerst von Beaudry und Koop (1993) aufgegriffen.⁷ Sie konstruieren anhand des logarithmierten BIPs eine zusätzliche Regressorvariable,

⁷Das verstärkte Wachstum nach Rezessionen ist gleichbedeutend mit einer Regimeabhängigkeit der Persistenz der Schocks. Negative Schocks setzen sich anders fort als positive, vgl. das zuvor dargestellte Modell von Potter

die die Tiefe der laufenden Kontraktion misst. Die Variable wird im Folgenden mit CDR_t (current depth of recession) bezeichnet. CDR_t ergibt sich als Differenz des laufenden BIPs von dem bisherigen Maximum der BIP-Zeitreihe.

Die Aufnahme der Verzögerten von CDR_t in das lineare Modell ermöglicht eine unterschiedliche Anpassung an negative Schocks im Vergleich zu positiven. Beaudry und Koop finden einen signifikanten Effekt dieses Regressors für US-Daten, so dass auf eine Rezession mit einem anschließend erhöhten Wachstum reagiert wird, wobei die Stärke der Rezession die Reaktion selber verstärkt. Rezessionen haben für den betrachteten Zeitraum in der USA eine entsprechend verringerte Langzeitwirkung auf die Niveauvariable (BIP).

Pesaran und Potter (1997) haben das Modell von Beaudry und Koop (1993) in mehrfacher Hinsicht erweitert. Neben dem von Beaudry und Koop eingeführten Effekt, der eine Dämpfung der Rezession und ein beschleunigtes Wachstum danach ermöglicht und bei Pesaran und Potter als “Floor”-Regime bezeichnet wird, unterstellen Pesaran und Potter einen ähnlichen Effekt bei zu hohem Wachstum. Durch den “Ceiling”-Effekt, der in die Mittelwertgleichung als HC_t eingeht, wird hohes (über dem durchschnittlichen Wachstum liegendes) Wachstum im Verlauf wiederum gedämpft. Neben diesem zusätzlichen Effekt wird die Variable CDR_t reformuliert und der Schwellenwert r_F als Parameter aufgefasst und nicht wie in Beaudry und Koop (1993) auf null gesetzt. Ferner wird Heteroskedastie in Form einer von den “Floor” und “Ceiling”-Regimen abhängigen Fehlervarianz zugelassen. Das Floor-Ceiling-Modell stellt sich wie folgt dar:

$$y_t = \mu + \sum_{\ell=1}^k \phi_{\ell} y_{t-\ell} + \theta_1 CDR_{t-1}(\gamma) + \theta_2 HC_{t-1}(\gamma) + \eta_t h_t(\gamma, \sigma) \quad (2.11)$$

wobei der bedingte Skalierungsfaktor $h_t(\gamma, \sigma)$ gegeben ist als

$$h_t(\gamma, \sigma) = \sigma_0(1 - \max\{F_{t-1}, C_{t-1}\}) + \sigma_1 F_{t-1} + \sigma_2 C_{t-1}$$


und η_t eine standardnormalverteilte Störgröße bezeichnet. Ferner gilt $\gamma = (r_F \ r_C)$ sowie $\sigma = (\sigma_0 \ \sigma_1 \ \sigma_2)$. Die Parameter θ_1 und θ_2 steuern die “Floor”- und “Ceiling”-Effekte im Hinblick auf den bedingten Mittelwert, während σ_1 und σ_2 den Einfluss des “Floor”- und “Ceiling” auf die Standardabweichung bzw. Varianz abbilden.

Die Dummy-Variable C_t kennzeichnet das “Ceiling”-Regime und HC_t den korrespondierenden Regressor, während die Variable F_t der Dummy ist, der das “Floor”-Regime kennzeichnet und CDR_t der Regressor, der die Tiefe der Rezession angibt. Diese Größen bilden sich wie folgt:

$$F_t = \begin{cases} \mathbf{1}(y_t < r_F), & \text{falls } F_{t-1} = 0, \\ \mathbf{1}(CDR_{t-1} + y_t < 0), & \text{falls } F_{t-1} = 1. \end{cases} \quad (2.12)$$

(1995).

Abbildung 2.1: Regressoren im Floor-Ceiling-Modell



Links: “hard ceiling” HC ; rechts: “current depth of recession” CDR ; jeweils gestrichelt: Rezessionen gemäß Bry-Boschan-Algorithmus

Fällt die Wachstumsrate unter den Schwellenwert, wird das “Floor”-Regime aktiviert. Das Regime dauert solange an, bis der Effekt der Kontraktion überwunden ist. Die Variable CDR_t baut sich während des “Floor”-Regimes auf und ergibt sich als:

$$CDR_t(\gamma) = \begin{cases} (y_t - r_F)F_t, & \text{falls } F_{t-1} = 0, \\ (CDR_{t-1} + y_t)F_t, & \text{falls } F_{t-1} = 1. \end{cases} \quad (2.13)$$

Das “Ceiling”-Regime tritt dann ein, wenn die Wachstumsraten über ihrem Mittelwert liegen (als Schwellenwert wird $r_c = \bar{y}$ angenommen). Durch die Berücksichtigung des Terms HC_{t-1} bei der Bestimmung von C_t werden zusätzlich die vergangenen Perioden mit überdurchschnittlichen Wachstumsraten mit einbezogen.

$$C_t = \mathbf{1}(HC_{t-1} + y_t > r_C) \quad (2.14)$$

$$HC_t(\gamma) = (HC_{t-1} + y_t - r_C)C_t, \quad HC_0 = 0. \quad (2.15)$$

Da die Regressoren CDR_t und HC_t von den Parameterschätzungen abhängen, kann man sie nicht a priori darstellen. Abbildung 2.1 zeigt die beiden Regressoren basierend auf der Schätzung für das deutsche BIP-Wachstum, siehe Abschnitt 2.4. Für die hier dargestellte Spezifikation des Modells wählen Pesaran und Potter die Formulierung “hard ceiling”, die sich auch in der Benennung der Variable HC_t wiederfindet. Sie beruht darauf, dass das “Ceiling”-Regime gilt, solange nicht sämtliche überdurchschnittlichen Entwicklungen abgebaut sind, die Niveauvariable

also wieder zu ihrem langfristigen Trend zurückgekehrt ist.⁸ In dieser Spezifikation können beide Effekte, Floor und Ceiling, parallel auftreten.

Zumindest für die “hard ceiling” Spezifikation kann das Floor-Ceiling-Modell in dem Sinne interpretiert werden, dass das BIP um seinen langfristigen Trend schwankt und es Mechanismen gibt, die Abweichungen von diesem Pfad revidieren. Das Modell steht damit im Widerspruch zur klassischen Real-Business-Cycle-Theorie, die Langfristwirkungen der Schocks impliziert.

Die ML-Schätzung des Floor-Ceiling-Modells weist das gleiche Problem wie die des SETAR-Modells auf. Die Likelihood ist nicht differenzierbar in r_f . Wiederum wird eine Gittersuche über die Schwellenwerte durchgeführt.

2.1.6 Regime-Wechsel-Modell

DeJong et al. (2005) schlagen ein Modell vor, das Aspekte des Floor-Ceiling-Modells wie des Markov-Switching-Modells beinhaltet. In diesem Modell (in der Folge DLR-Modell) wechseln sich Phasen bzw. Regime mit sich beschleunigendem und sich entschleunigendem Wachstum ab. Innerhalb eines Regimes folgt das Wachstum einer Trajektorie. Die Trajektorien sind stochastisch und können zwischen den Regimen variieren. Die Idee unbeobachtbarer Regimewechsel zeigt die Nähe des Modells zu MS-Modellen. Die Zustandsvariable folgt allerdings keinem Markov-Prozess, sondern die Regimewechsel werden von einem beobachtbaren “Spannungsindex” hervorgerufen. Der “Spannungsindex” h_t ergibt sich als geometrische Summe der Abweichungen vergangener Wachstumsraten vom “nachhaltigen” Wachstum y_t^* :


$$h_t = \sum_{\ell=1}^{\infty} \delta^{\ell} (y_{t-\ell} - y_t^*), \quad (2.16)$$

wobei der Parameter $\delta \in (0, 1)$ die Persistenz der vergangenen Abweichungen abbildet. Als nachhaltige Wachstumsrate wird von DeJong et al. (2005) der Mittelwert eingesetzt, als Alternative nennen die Autoren gefilterte Trendvariablen. Im weiteren wird das mittlere Wachstum als nachhaltiges Wachstum und für δ der Wert 0,575 angenommen. Basierend auf $\delta = 0,575$ ergibt sich für deutsche BIP-Daten der in Abbildung 2.2 dargestellte Spannungsindex.

Der “Spannungsindex” zeigt Analogien zum Floor-Ceiling-Modell auf. Abweichungen von einem langfristigen Trend führen auch im DLR-Modell zu Anpassungsreaktionen, jedoch nicht in Form eines anwachsenden Regressors, sondern als Regimewechsel. Durch die Annahme, dass die Wachstumsraten während des Regimes einem Trend folgen, in Kontraktionen einem negativen und in Expansionen einem positiven, können die Regimewechsel nicht zum Eintritt in eine nachhaltige Phase führen.

⁸Pesaran und Potter (1997) verwenden außerdem die Spezifikation “over heating”, bei der $C_t = \mathbf{1}(y_t > r_C)$ und folglich vergangene überdurchschnittliche Entwicklungen zu keinen Anpassungen führen.

Abbildung 2.2: Spannungsindex im DLR-Modell – $\delta = 0,575$



Die Regimewechsel folgen einem Probit-Modell, dessen Wahrscheinlichkeiten vom Spannungsindex beeinflusst werden:

$$\pi_{t+1} = P(r_{t+1} = -r_t | r_t, h_t) = \Phi(\beta_0 + \beta_1 r_t h_t), \quad (2.17)$$

mit

$$r_t = \begin{cases} 1, & \text{falls } t \text{ in einem expansivem Regime ist} \\ -1, & \text{falls } t \text{ in einem kontraktivem Regime ist} \end{cases},$$

wobei Φ die Verteilungsfunktion der Standardnormalverteilung darstellt. Dadurch, dass die Regimevariable im Probit-Modell mit dem Spannungsindex multipliziert wird, wird ein Regimewechsel immer dann wahrscheinlich, wenn in einem kontraktivem Regime der Spannungsindex hohe negative Werte annimmt oder wenn in einem expansivem Regime der Spannungsindex hohe positive Werte annimmt. Die Wachstumsraten werden im DLR-Modell wie folgt dargestellt:

$$y_t = m_t + \nu h_{t-1} + \gamma y_{t-1} + \epsilon_t, \quad \epsilon_t \sim \mathcal{N}(0, \sigma^2). \quad (2.18)$$

Die Variable m_t repräsentiert den Regimedrift in Form lokaler Trends

$$m_t = a_j + b_j r_t \sum_{v=1}^{t-t(j-1)-1} d^{v-1}, \quad b_j > 0, \quad t = t(j-1) + 1, \dots, t(j), \quad (2.19)$$

wobei j ($j : 1 \rightarrow J$) das zum Zeitpunkt t geltende Regime bezeichnet und $t(j)$ den Zeitpunkt des Wechsels von Regime j zu $j+1$ (d.h. $t(j)$ ist die letzte Periode des Regimes j wobei $t(0) \equiv 0$). Der Parameter a_j bezeichnet den Wert des Regimedrifts in der ersten Periode des j ten Regimes. Der Term b_j gibt die Steigung und die Zustandsvariable r_t die Richtung des Trends an. Der Parameter d steuert die Krümmung des Trends. Bei $d = 1$ ist der Trend linear.

In der empirischen Anwendung werden abweichend von DeJong et al. (2005), die für US-Daten d mitschätzen, vereinfachend lineare Trends unterstellt, also d gleich eins gesetzt. Die Parameter a_j und b_j werden als Zufallsvariablen modelliert. a_j entstammt einer Normalverteilung mit den Parametern $\mu_{a,1}$ bzw. $\mu_{a,2}$ und σ_a . Sofern es sich um ein kontraktives Regime handelt gilt $\mu_{a,1}$. Für expansive Regime wird $\mu_{a,2}$ als Erwartungswert der a_j angenommen.⁹ Für die b_j eine Log-Normalverteilung mit den Parametern μ_b und σ_b angenommen, um die strikte Positivität der b_j sicherzustellen.

Die Regime bzw. die Zustandsvariable r_t ist analog zur Zustandsvariable in MS-Modellen latent. Der Hamilton-Filter kann hier jedoch nicht eingesetzt werden, da sich die Regime untereinander nicht gleichen. Eine endliche Übergangsmatrix kann daher nicht bzw. nicht ohne unmäßigen Aufwand spezifiziert werden. Die im Folgenden dargestellte Likelihoodfunktion gibt eine Sequenz von r_t , die eine Anzahl von J verschiedenen Regimen impliziert. Sie entspricht der gemeinsamen Dichte der Wachstumsraten y_t und der Zustandsvariablen r_t :

$$L(\Theta; \{y_t\}_{t=1}^T, \{r_t\}_{t=1}^T) = \prod_{j=1}^J \int_{a_j} \int_{b_j} f(Y_j, R_j, a_j, b_j, \Theta) da_j db_j, \quad (2.20)$$

wobei

$$f(Y_j, R_j, a_j, b_j, \Theta) = \prod_{t=t(j-1)+1}^{t(j)} \frac{1}{\sigma} \phi\left(\frac{y_t - m_t - \nu h_{t-1} - \gamma y_{t-1}}{\sigma}\right) \cdot \frac{1}{\sigma_a} \phi\left(\frac{a_j - \mu_{a,(r_{t(j)}+3)/2}}{\sigma_a}\right) \frac{1}{\sigma_b} \phi\left(\frac{\ln b_j - \mu_b}{\sigma_b}\right) \pi_t^{\tilde{r}_t} (1 - \pi_t)^{(1-\tilde{r}_t)} \quad (2.21)$$

$\phi(\cdot)$ bezeichnet die Dichtefunktion der Standardnormalverteilung. Y_j sowie R_j bezeichnen die Vektoren der Wachstumsraten sowie der Zustandsvariablen während des Regimes j . \tilde{r}_t nimmt den Wert 1 an, wenn Wechsel in der Regimevariablen r_t auftreten und sonst den Wert 0. Das angegebene Doppelintegral kann mit Hilfe einer Gauss-Hermite-Quadratur gelöst werden. Die Likelihoodfunktion kann folglich mit numerischen Algorithmen über die Parameter Θ maximiert werden.

DeJong et al. (2005) schlagen zur Behandlung der latenten Variablen r_t zwei Vorgehensweisen vor. Zum einen wird über einen Algorithmus eine optimale Sequenz für r_t gesucht und basierend auf dieser Sequenz werden dann Inferenz und Vorhersage betrieben. Eine zweite Vorgehensweise besteht darin die Likelihood über die Sequenz r_t zu integrieren. Da die Anzahl möglicher Sequenzen zu groß ist, schlagen DeJong et al. (2005) die Verwendung eines Importance-Samplers vor um den Rechenaufwand handhabbar zu halten. Im Rahmen der Diskussion der Modellgüte in Abschnitt 2.5 wird der Ansatz über den Importance-Sampler im Detail erläutert.

⁹Wenn die Verteilung anhand der Zustandsvariablen r_t definiert wird, ergibt sich folgender Ausdruck für den Erwartungswert von a_j : $\mu_{a,(r_{t(j)}+3)/2}$.

Die zuerst genannte Vorgehensweise betreibt Inferenz bedingt auf eine explizite Sequenz von r_t , die über den folgenden Algorithmus bestimmt werden kann. Es wird eine Startsequenz für r_t bestimmt. Da die Regime im Zusammenhang mit dem Konjunkturzyklus zu sehen sind, schlagen DeJong et al. (2005) für die USA die NBER Datierungen für Konjunkturwechsellpunkte vor. Für Deutschland besteht keine eindeutige Referenzserie, so dass der Bry-Boschan-Algorithmus verwendet wird um eine Startsequenz zu generieren.¹⁰ Für diese Startsequenz wird eine ML-Schätzung durchgeführt. Anschließend werden die Regimewechsellpunkte sequentiell überprüft. Dies geschieht wie folgt: Gegeben die ML-Schätzung und alle andere Regimewechsellpunkte wird die Likelihood für alle möglichen Werte des Regimewechsellpunkts $t(j)$ berechnet, wobei $t(j)$ zwischen $t(j-1)$ und $t(j+1)$ abzüglich der Mindestregimedauer von zwei Quartalen liegen kann. Die Likelihoodwerte eines möglichen Regimewechsellpunkts werden durch ihre Summe geteilt und können als Wahrscheinlichkeiten aufgefasst werden. Der Punkt mit der höchsten Wahrscheinlichkeit wird als neuer Regimewechsellpunkt $t(j)$ festgelegt. Ferner wird auch geprüft, ob das Entfernen des Regimewechsellpunkts die Likelihood verbessert. Das Gleiche geschieht dann mit dem nächsten Regimewechsellpunkt. Wenn alle Regimewechsellpunkte entsprechend behandelt worden sind, wird gegeben die resultierende Sequenz wiederum eine ML-Schätzung durchgeführt und die Regimewechsellpunkte nach dem eben geschilderten Verfahren erneut überprüft. Dieses Vorgehen wird solange iteriert, bis sich die Sequenz nicht mehr ändert.

2.2 Daten zum BIP-Wachstum in Deutschland


Die Untersuchung basiert auf saisonbereinigten Quartalsdaten des deutschen BIP der Jahre 1970 bis 2006. Es handelt sich dabei um die annualisierten Quartalswachstumsraten, die vom Statistischen Bundesamt Deutschland für den Zeitraum vor 1991 (Wiedervereinigung) für Westdeutschland und danach für Gesamtdeutschland bereitgestellt werden, siehe Fachserie 18 Reihe S.28 und Fachserie 18 Reihe 1.3 jeweils aus dem Erscheinungsjahr 2006.¹¹ Entsprechend wird die zu analysierende Zeitreihe aus diesen beiden Teilstücken zusammengesetzt. Die Daten beider Teilstücke werden konsistent entsprechend der jüngsten Bestimmung zur Volkswirtschaftlichen Gesamtrechnung berichtet, siehe Räth und Braakmann (2006).

Der Mittelwert der zu analysierenden Wachstumsraten beträgt 2,11 und die Standardabweichung ist 3,633. Die Schiefe beträgt -0,096 und die Wölbung 3,56. Der asymptotische p -Wert des korrespondierenden Jarque-Bera-Tests beträgt 0,354. In Abbildung 2.3 sind die Wachstumsraten des deutschen BIP dargestellt.

¹⁰Einzelheiten und Erläuterungen zum Bry-Boschan-Algorithmus finden sich in Abschnitt 3.3.

¹¹Aus der gleichen Veröffentlichung werden auch die Daten zu den Komponenten des BIP, die in Kapitel 4 verwendet werden, entnommen.

Abbildung 2.3: Quartalswachstumsraten des deutschen BIP



2.3 Literaturübersicht zu nicht-linearen Zeitreihenmodellen für deutsche BIP-Daten

Im Gegensatz zu den USA existiert keine umfangreiche Literatur, die nicht-lineare Modelle auf deutsche Daten anwendet. Teilweise werden deutsche Daten im Rahmen internationaler Studien berücksichtigt. Goodwin (1993) findet für deutsche BSP-Daten von 1960 bis 1990, dass das MS-Modell im Mittelwert (MSM) zwar im Wesentlichen die durch alternative Methoden, wie dem Bry-Boschan-Algorithmus, bestimmten Rezessionen anzeigt, aber nach dem Test von Hansen (1992) ist das MS-Modell nicht signifikant im Vergleich zu einem AR-Modell. Für eine etwas andere Zeitspanne (1955 bis 1990) und BIP Daten finden Kähler und Marnet (1994) bei der Anwendung des gleichen Modells zuviele kurzzeitige Phasen für das Regime mit dem geringeren Mittelwert verglichen mit der Anzahl an Rezessionen, die mit anderen Verfahren bestimmt werden. Die Ergebnisse der Autoren zu einem MSMH-Modell, in dem neben dem Mittelwert auch die Varianz regimeabhängig ist, deuten auf einen Bruch in den siebziger Jahren hin, vgl. auch Mills und Wang (2003) sowie Kapitel 4. Die Ergebnisse von Krolzig (1997) zum MSM-Modell für das deutsche BIP entsprechen denen von Goodwin (1993). Ein alternatives MS-Modell verwenden Fritsche und Kuzin (2005a), die die autoregressiven Parameter regimeabhängig gestalten mit dem Ziel Volatilitätsschwankungen zu erklären.

Potter (1995) hat für die USA die Verwendung von Schwellenwertmodellen vorgeschlagen. Für deutsche Daten findet sich in Kiani und Bidarkota (2004) eine Anwendung des SETAR-Modells für das deutsche BIP-Wachstum zwischen 1960 und 2000. Sie finden Evidenz für ein solches Modell verglichen mit einem linearen AR-Modell. Cancelo und Mourelle (2005) wenden Verallgemeinerungen des SETAR-Modells in Form des LSTAR- und des ESTAR-Modells an,

in denen die Schwellenvariable keinen Bruch, sondern einen allmählichen Übergang steuert, und finden für Deutschland zwischen 1970 und 2002 keine Evidenz für diese Form der Nicht-Linearität.

Die Vorstufe des Floor-Ceiling-Modells ist das Modell von Beaudry und Koop (1993), welches einen zusätzlichen von der vorangegangenen Rezession abhängigen Regressor berücksichtigt, der Asymmetrien in der Schockpropagierung zwischen den Konjunkturphasen aufzeigen kann. Bradley und Jansen (1997) wenden das Modell auf BIP-Daten der G 7 an und finden für deutsche Daten zwischen 1960 und 1993 Evidenz für eine solche Form der Asymmetrie. Die Autoren sprechen von einem "overshooting", da entsprechend der Ergebnisse zum Modell von Beaudry und Koop (1993) für deutsche Daten nach Rezessionen ein erheblich verstärktes Wachstum eintritt.

Eine Arbeit, die verschiedene nicht-lineare Modelle für deutsche Daten miteinander vergleicht liegt noch nicht vor. In Kiani und Bidarkota (2004) werden jedoch mehrere nicht-lineare Modelle verwendet, die allerdings nicht miteinander verglichen werden, sondern alle dem Zweck dienen Zeitreiheneigenschaften des BIP-Wachstums zu untersuchen.

2.4 Schätzergebnisse

In diesem Abschnitt werden die Eigenschaften der in Abschnitt 2.1 dargestellten Modelle für das Quartalswachstum des realen saisonbereinigten deutschen BIP anhand der ML-Schätzungen diskutiert. Die Tabelle 2.1 gibt die Ergebnisse für das AR-, das MSA- und das MSAH-Modell wieder. Dabei werden die Punktschätzungen und die dazugehörigen, asymptotischen Werte der t -Statistik sowie als Kriterien für die Modellgüte das R^2 , das adjustierte R^2 , die logarithmierte Likelihood und AIC sowie BIC berichtet.¹² Ferner werden die Ljung-Box-Statistiken samt p -Werte für die Residuen und die quadrierten Residuen angegeben, wobei nur die Werte für eine und vier Verzögerte berichtet werden. Die Ljung-Box-Statistiken für andere Horizonte sind nicht signifikant zum 10 % Niveau. Als Ausgangspunkt für den Vergleich der nicht-linearen Modelle wird ein AR(4)-Modell angenommen. Bezogen auf AIC und BIC zeigt es sich anderen ARMA-Modellen gegenüber überlegen. Es findet sich signifikante Autokorrelation in den Daten, die insbesondere durch den vierten autoregressiven Parameter aufgefangen wird, so dass die Ljung-Box-Statistik keine weitere Autokorrelation in den Residuen des AR(4)-Modells aufzeigt. Für ARCH-Effekte gibt es geringe Evidenz angesichts eines p -Werts von 0,106 der Ljung-Box-Statistik für die quadrierten Residuen.

Fritsche und Kuzin (2005a) diskutieren die Instabilität der autoregressiven Parameter für das deutsche BIP-Wachstum. Daher bietet sich das MSA-Modell, das Regimewechsel in der Autokorrelation erlaubt, als Kandidat zur Beschreibung des deutschen BIP-Wachstums an. Die zwei Zustände unterscheiden sich insbesondere durch den vierten autoregressiven Parameter.

¹²Zur Berechnung des R^2 in MS-Modellen siehe Krolzig (1997), Seite 133.

Tabelle 2.1: Schätzergebnisse des AR-, MSA- und MSAH-Modells

AR-Modell		MSA-Modell		MSAH-Modell	
μ	2,161 4,937	p_{11}	0,858 9,365	p_{11}	0,815 8,952
ϕ_1	-0,017 -0,210	p_{22}	0,817 6,332	p_{22}	0,679 4,066
ϕ_2	0,031 0,389	μ	1,359 3,403	μ	1,136 3,439
ϕ_3	0,083 1,040	$\phi_{1,1}$	-0,033 -0,290	$\phi_{1,1}$	-0,132 -1,409
ϕ_4	0,236 3,101	$\phi_{1,2}$	0,016 0,142	$\phi_{1,2}$	0,059 0,605
σ^2	11,998	$\phi_{1,3}$	-0,027 -0,228	$\phi_{1,3}$	0,076 0,751
		$\phi_{1,4}$	0,548 5,565	$\phi_{1,4}$	0,529 5,597
				σ_1^2	11,142 6,379
		$\phi_{2,1}$	0,129 0,964	$\phi_{2,1}$	0,402 4,585
		$\phi_{2,2}$	0,115 0,871	$\phi_{2,2}$	0,048 0,565
		$\phi_{2,3}$	0,249 1,873	$\phi_{2,3}$	0,180 2,244
		$\phi_{2,4}$	-0,372 -2,574	$\phi_{2,4}$	-0,431 -5,495
		σ^2	8,355 6,935	σ_2^2	2,573 3,235
R^2	0,075	R^2	0,125	R^2	0,105
ad R^2	0,048	ad R^2	0,058	ad R^2	0,036
logLik	-372,696	logLik	-366,268	logLik	-360,002
AIC	5,357	AIC	5,366	AIC	5,291
BIC	5,462	BIC	5,617	BIC	5,563
$Q_1(\epsilon)$	0,334 0,564	$Q_1(\epsilon)$	0,013 0,908	$Q_1(\epsilon)$	0,027 0,870
$Q_4(\epsilon)$	3,315 0,507	$Q_4(\epsilon)$	0,523 0,971	$Q_4(\epsilon)$	0,562 0,967
$Q_1(\epsilon^2)$	2,619 0,106	$Q_1(\epsilon^2)$	2,790 0,095	$Q_1(\epsilon^2)$	2,153 0,142
$Q_4(\epsilon^2)$	5,504 0,239	$Q_4(\epsilon^2)$	4,768 0,312	$Q_4(\epsilon^2)$	5,415 0,247

Unter den Werten der Punktschätzungen stehen die t -Statistiken. Q_1 bezeichnet die Ljung-Box-Statistik für eine Verzögerte, Q_4 für vier Verzögerte. Der p -Wert ist unter den Wert der Ljung-Box-Statistik gesetzt.

In einem Zustand ist er signifikant positiv und im anderen signifikant negativ. Die geglätteten Wahrscheinlichkeiten der Zustände bieten allerdings keine intuitive Interpretation anhand der Konjunkturphasen für dieses Muster, siehe Abbildung 2.4. Außerdem favorisieren beide Kriterien, sowohl AIC wie BIC, das AR-Modell im Vergleich zum MSA-Modell.

Die Ljung-Box-Statistik der quadrierten Residuen des MSA-Modells nimmt den p -Wert 0,095 an. Das MSA-Modell wird zum MSAH-Modell erweitert, in dem auch die Varianz zustandsabhängig ist. Die Inferenz über die Zustände, sowie die Schätzungen der AR-Koeffizienten weisen starke Übereinstimmungen mit dem restriktiverem MSA-Modell auf. Zustand 2 ist im MSAH-Modell jedoch weniger persistent (MSA: $\hat{p}_{22} = 0,817$; MSAH: $\hat{p}_{22} = 0,679$), dafür weist Zustand 2 eine erheblich verringerte Varianz auf. Dabei ist bemerkenswert, dass insbesondere im Vergleich zum MSA-Modell die Wahrscheinlichkeit für den Zustand 2 am Ende der Stichprobe relativ hoch ist, was mit der Evidenz für eine Varianzreduktion des deutschen BIP-Wachstums in den 90er Jahren korrespondiert.¹³ Die Ljung-Box-Statistiken für die quadrierten Residuen des MSAH-Modells zeigen als geringsten p -Wert 0,142 an. Die Aufnahme dieser Form der Heteroskedastie führt zu einem erheblichen Zugewinn in der Likelihood, so dass das AIC dieses Modell gegenüber dem AR-Modell bevorzugt.

In der Tabelle 2.2 werden die Ergebnisse des MSI-, MSIH- und des Bounce-Back-Modells berichtet. Das MSI-Modell wird hier im Gegensatz zum MSM-Modell von Hamilton (1989) verwendet, da es bei nahezu gleichen Ergebnissen die deutschen Daten etwas besser beschreibt. Der Unterschied der Modellierung ist, dass das MSM-Modell abrupte Folgen des Regimewechsels impliziert, während im MSI-Modell das alte Regime über die autoregressiven Parameter "fortbesteht". Die Interpretation ist allerdings abgesehen von diesem Unterschied analog zum MSM-Modell zu sehen. Die Schätzung des MSI-Modells ergibt zwei ähnlich persistente Zustände, die sich nicht als Rezession und Expansion wie in Hamilton (1989) für die USA oder in Goodwin (1993) sowie Krolzig (1997) für Deutschland, sondern eher als zwei unterschiedliche Trendwachstumsraten mit geschätzten 0,751% bzw. 4,206% interpretieren lassen. Die geglätteten Wahrscheinlichkeiten der Zustände sind in Abbildung 2.5 zu finden.¹⁴ Die Rezessionen entsprechend der Definition über den Bry-Boschan-Algorithmus fallen erwartungsgemäß in die Perioden mit hohen Wahrscheinlichkeiten für niedriges Trendwachstum.¹⁵ Diese Ergebnisse und Interpretationen des MSI-Modells entsprechen der Diskussion, dass Deutschland ab der zweiten Hälfte der 90er kein eigentlich konjunkturelles, sondern vielmehr strukturelles Phänomen erlebt hat, das im Sinne der Trennung von Lucas (1981) das Trendwachstum beeinflusst.¹⁶ Das MSI-Modell

¹³Vgl. Kapitel 4.

¹⁴Geglättete Wahrscheinlichkeiten bedingen die Inferenz über die Zustände auf die Beobachtungen der gesamten Stichprobe im Gegensatz zu gefilterten Wahrscheinlichkeiten, die nur Beobachtungen bis zum Zeitpunkt t berücksichtigen. Der hierzu verwendete Kim-Glätter ist in Anhang A.1 erläutert.

¹⁵Der Bry-Boschan-Algorithmus für Quartalsdaten wird in Abschnitt 3.3 erläutert.

¹⁶Zur Diskussion der Wachstumsschwäche in Deutschland in den 90er Jahren siehe z.B. Sachverständigenrat (2002) oder Weber und Hofmann (2006).

wird jedoch von keinem der Kriterien adjustiertes R^2 , AIC oder BIC gegenüber dem AR-Modell vorgezogen.¹⁷ Die Ljung-Box-Statistik weist einen p -Wert von 0,104 bei Berücksichtigung einer Verzögerten für die quadrierten Residuen auf. Analog zum MSA-Modell wird eine heteroskedastische Variante des Modells geschätzt (MSIH).

Das MSIH-Modell zeigt ein stark abweichendes Verhalten im Vergleich zum MSI-Modell. Die Inferenz über die Zustände ist dominiert von einem starken Rückgang der Varianz von 13,157 auf 2,453, die als Strukturbruch interpretiert werden kann, wenn man den Verlauf der geglätteten Zustandswahrscheinlichkeiten in Abbildung 2.5 betrachtet. Im Vergleich zum MSI-Modell ist die Berücksichtigung eines zusätzlichen Varianzparameters hoch signifikant, wobei das R^2 niedriger ist als im MSI-Modell. Das AIC zieht das MSIH-Modell sogar dem AR-Modell vor. Die angesprochene Varianzreduktion in den deutschen Daten wird auch in diesem Modell offensichtlich. Der Strukturbruch, dessen Datierung über die geglätteten Zustandswahrscheinlichkeiten betrieben werden kann, wird im MSIH später gefunden als in der Analyse im noch folgenden Kapitel 4. Dort wird eine Volatilitätsreduktion in Form eines Varianzbruchs auf 1993 datiert. Der gemeinsame Bruch von Varianz und Mittelwertparameter μ im MSIH-Modell korrespondiert mit der Arbeit von Kholodilin und Siliverstovs (2006), die unter Berücksichtigung von Daten ab 1991 einen gemeinsamen Bruch im Jahr 2001 datieren.

Das Bounce-Back-Modell, das an dieser Stelle zur Anwendung kommt, basiert auf dem MSI-Modell und nicht wie im Original von Kim et al. (2005) auf dem MSM-Modell. Das Bounce-Back-Modell, in dem das MSI-Modell genistet ist, ist laut adjustiertem R^2 sowie AIC und BIC diesem vorzuziehen. Die Inferenz über die beiden Zustände ist in Form der geglätteten Wahrscheinlichkeit für den kontraktiven Zustand ($\hat{\mu}_2 = -4,982$) in Abbildung 2.6 dargestellt. Nur vereinzelte Punkte bzw. negative Werte werden diesem Zustand zugeschlagen. Die Konjunkturphasen können kaum mit diesem Ergebnis übereingebracht werden. Die mittlere Dauer eines kontraktiven Regimes wird im Bounce-Back-Modell auf unter zwei Quartale geschätzt ($\hat{p}_{22} = 0,336$). Anstatt, wie von Kim et al. (2005) angedacht und für US Daten gefunden, den Übergang von der Rezession in die Expansion zu modellieren, bietet das Bounce-Back-Modell für deutsche Daten eher eine Erklärung für einzelne negative Extremwerte.

Neben den Markov-Switching-Modellen spielen Schwellenwertmodelle eine große Rolle in der nicht-linearen Modellierung makroökonomischer Zeitreihen. Das SETAR-Modell ergibt für deutsche Daten ein vergleichsweise hohes R^2 bzw. adjustiertes R^2 , siehe Tabelle 2.3. Bedeutende Unterschiede der beiden Zustände (der eine gilt auf der einen Seite der andere auf der anderen Seite des Schwellenwertes) zeigen sich insbesondere in der Form der autoregressiven Struktur und in der Varianz. In Abbildung 2.7 ist die geschätzte Verteilung der Regime zu sehen. Sie scheint keinem sonst bekannten Konjunkturmuster zu folgen. Die Verweildauer eines Zustands

¹⁷Für US-Daten hängt die Evidenz für das MSI bzw. MSM-Modell vom betrachteten Datensatz ab. Während Garcia (1998) die Nullhypothese eines linearen Modells zum 5% Niveau nicht ablehnen kann, kommen Kim et al. (2005) zu einem entgegengesetzten Ergebnis.

Tabelle 2.2: Schätzergebnisse des MSI-, MSIH- und Bounce-Back-Modells

MSI-Modell		MSIH-Modell		Bounce-Back-Modell	
p_{11}	0,850 7,224	p_{11}	0,993 117,579	p_{11}	0,915 20,667
p_{22}	0,897 8,265	p_{22}	0,979 23,359	p_{22}	0,336 2,034
μ_1	0,751 0,936	μ_1	0,592 1,499	$\mu_1 - \mu_2$	6,156 5,260
$\mu_2 - \mu_1$	3,455 4,136	$\mu_2 - \mu_1$	1,297 2,228	μ_2	-4,982 -3,739
ϕ_1	-0,148 -1,700	ϕ_1	-0,009 -0,110	ϕ_1	-0,021 -0,271
ϕ_2	-0,065 -0,744	ϕ_2	-0,009 -0,112	ϕ_2	0,099 1,305
ϕ_3	0,022 0,260	ϕ_3	0,053 0,692	ϕ_3	0,149 1,970
ϕ_4	0,202 2,569	ϕ_4	0,190 2,634	ϕ_4	0,315 4,013
σ^2	9,123 6,144	σ_1^2	2,453 3,237	γ	-0,426 -3,539
		σ_2^2	13,157 7,957	σ^2	7,217 6,496
R^2	0,094	R^2	0,087	R^2	0,111
ad R^2	0,047	ad R^2	0,039	ad R^2	0,057
logLik	-371,510	logLik	-367,036	logLik	-367,941
AIC	5,397	AIC	5,348	AIC	5,361
BIC	5,586	BIC	5,557	BIC	5,570
$Q_1(\epsilon)$	0,034 0,854	$Q_1(\epsilon)$	0,155 0,694	$Q_1(\epsilon)$	0,0013 0,971
$Q_4(\epsilon)$	0,315 0,989	$Q_4(\epsilon)$	0,425 0,980	$Q_4(\epsilon)$	0,0771 0,999
$Q_1(\epsilon^2)$	2,639 0,104	$Q_1(\epsilon^2)$	1,143 0,285	$Q_1(\epsilon^2)$	0,4635 0,496
$Q_4(\epsilon^2)$	6,357 0,174	$Q_4(\epsilon^2)$	3,777 0,437	$Q_4(\epsilon^2)$	7,4037 0,116

Unter den Werten der Punktschätzungen stehen die t -Statistiken. Q_1 bezeichnet die Ljung-Box-Statistik für eine Verzögerte, Q_4 für vier Verzögerte. Der p -Wert ist unter den Wert der Ljung-Box-Statistik gesetzt.


ist relativ kurz und die Wechsel der Zustände sind relativ häufig. So wird der Schwellenwert mit $\hat{r} = 2,4$ nahe dem durchschnittlichen Wachstum geschätzt und nicht wie zum Beispiel für US Daten von Potter (1995) nahe Null. Die Zustände lassen sich also für diese Schätzung deutscher Daten nicht als Rezession und Expansion unterscheiden.

Das Floor-Ceiling-Modell weist im Vergleich zu den bisher aufgeführten Modellen die besten AIC- und BIC-Werte auf. Im Gegensatz zur von Pesaran und Potter (1997) für die USA favorisierten Spezifikation wird hier das für deutsche Daten überlegene “Hard-Ceiling” verwendet. Ferner wird aus Gründen der Identifikation auf einen dritten Varianzparameter verzichtet. Im Optimum ist nur in zwei Beobachtungen weder der “Floor” noch der “Ceiling”-Effekt aktiv. Der Regressor CDR , dessen Verlauf in Abbildung 2.1 dargestellt ist, weist einen signifikant geschätzten Parameter auf. Hier sind Ähnlichkeiten beim Vergleich der geglätteten Wahrscheinlichkeiten im Bounce-Back-Modell mit der Variable CDR unverkennbar. Schließlich werden auch beide Modelle über eine ähnliche Idee motiviert, dass besonders ausgeprägte (stark negative und beim Floor-Ceiling-Modell auch positive) Entwicklungen entgegengesetzte Anpassungen hin zu einem langfristigen Trend nach sich ziehen. Der besonders gute Fit des Floor-Ceiling-Modells ist jedoch insbesondere auf die Berücksichtigung der Heteroskedastie zurückzuführen. In Abbildung 2.1 ist zu sehen, dass der Ceiling-Effekt, der mit einer hohen Varianz einhergeht, erst gegen Ende der Stichprobe aussetzt. Dieser Umstand korrespondiert mit den Ergebnissen des MSIH-Modells, in dem ein (Quasi-) Strukturbruch am Ende der Stichprobe ebenfalls mit einer erheblichen Reduktion der Fehlervarianz einhergeht. Die Bedeutung der Varianzmodellierung zeigt sich, wenn man das Floor-Ceiling-Modell ohne Heteroskedastie schätzt. Dann ergibt sich bei leicht verbessertem R^2 ein Likelihoodwert von $-367,399$ im Vergleich zu $-362,668$ mit einem zusätzlichen Varianzparameter. Die Ergebnisse von Bradley und Jansen (1997), die im Rahmen des Modells von Beaudry und Koop (1993) eine erhebliche Bedeutung des “Ceiling”-Effekts auf den bedingten Mittelwert der deutschen Daten finden, können also für die hier verwendeten jüngeren Daten nicht vollständig bestätigt werden. Die Punktschätzung von θ_1 zusammen mit den Punktschätzungen der autoregressiven Parameter sprechen zwar für die Existenz von einem dem “overshooting” in Bradley und Jansen (1997) ähnlichen Aufholeffekt nach Rezessionen, er ist allerdings bedeutend geringer und der hohe Likelihoodwert des Floor-Ceiling-Modells geht insbesondere auf die Modellierung der Varianz zurück.¹⁸

Von allen Modellen weist das DLR-Modell das höchste R^2 auf, siehe Tabelle 2.3. Die Anpassung der zufälligen Niveau- und Trendkomponente an die Daten ist in Abbildung 2.7 rechts zu sehen. Die geschätzten Werte für m_t sind dort zusammen mit den um die anderen geschätzten Mittelwertbestandteile bereinigten Wachstumsraten $y_t - \hat{\nu}h_{t-1} - \hat{\gamma}y_{t-1}$ abgebildet. Insgesamt haben sich neun Regime mit der in Abbildung 2.7 rechts zu sehenden Abfolge als optimal erwiesen. Die Rezessionen entsprechend des Bry-Boschan-Algorithmus fallen sämtlich in Perioden, die

¹⁸Die Ergebnisse des homoskedastischen Floor-Ceiling-Modells werden an dieser Stelle nicht weiter verfolgt.

Abbildung 2.4: Zustandswahrscheinlichkeiten MSA und MSAH



Links: Zustandswahrscheinlichkeiten des MSA-Modells; rechts: Zustandswahrscheinlichkeiten des MSAH-Modells; jeweils gestrichelt: Rezessionen gemäß Bry-Boschan-Algorithmus

Regimen mit sich verlangsamendem Wachstum zuzuordnen sind.¹⁹ Die Werte für die Modelldiagnostiken Likelihood, AIC und BIC sind für das DLR-Modell mit denen der anderen Modelle jedoch nicht vergleichbar. Die Ergebnisse beziehen sich auf das bedingte Schätzverfahren, in dem die durch den Algorithmus bestimmte Sequenz angenommen wird und die Likelihood sich auf die gemeinsame Wahrscheinlichkeitsdichte- bzw. massenfunktion der Sequenz der Zustände und Sequenz der beobachtbaren Wachstumsraten bezieht, vgl. Gleichung 2.20. Unbedingte Werte für den Modellvergleich werden mit Hilfe eines Importance-Sampling-Verfahrens, durch welches r_t herausintegriert wird, in Form der Marginalen Likelihood in Abschnitt 2.5 diskutiert.

Bezogen auf das BIC gibt es nur ein Modell, das Floor-Ceiling-Modell, welches außerdem nur knapp besser als das AR-Modell abschneidet. Dabei ist zu beachten, dass das DLR-Modell in der bedingten Form nicht über das AIC oder BIC mit den anderen Modellen verglichen werden kann. Bezogen auf das AIC existieren einige weitere Kandidaten wie das MSAH- oder das SETAR-Modell, die besser abschneiden als das AR-Modell.


¹⁹Der Eindruck, dass das DLR-Modell die Konjunkturphasen des deutschen BIP gut abbilden kann, wird in Kapitel 3 bestätigt.

Tabelle 2.3: Schätzergebnisse des SETAR-, Floor-Ceiling- und DLR-Modells

SETAR-Modell		Floor-Ceiling-Modell		DLR-Modell	
μ_1	0,858 2,053	μ	1,363 3,133	ν	-0,168 -1,352
$\phi_{1,1}$	0,232 2,457	ϕ_1	0,142 1,583	γ	-0,061 -0,459
$\phi_{1,2}$	-0,042 -0,300	ϕ_2	0,072 0,945	β_0	4,601 4,730
$\phi_{1,3}$	0,020 0,196	ϕ_3	0,066 0,842	β_1	-0,426 -3,113
$\phi_{1,4}$	0,292 2,840	ϕ_4	0,236 3,259	$\mu_{a,1}$	0,479 0,645
σ_1^2	7,261 6,734	σ_1^2	11,694 7,541	$\mu_{a,2}$	1,803 1,539
μ_2	0,996 0,865	σ_2^2	1,359 2,683	μ_b	-2,097 -4,800
$\phi_{2,1}$	-0,321 -2,528	θ_1	-0,506 -2,745	σ_a^2	1,054 1,959
$\phi_{2,2}$	0,319 1,587	θ_2	-0,036 -1,468	σ_b^2	0,025 0,035
$\phi_{2,3}$	0,041 0,353	r_f^*	-1,694	σ^2	9,313 9,260
$\phi_{2,4}$	0,115 1,073				
σ_2^2	13,999 11,921				
r^*	2,400				
q^*	2,000				
R^2	0,169	R^2	0,124	R^2	0,285
ad R^2	0,112	ad R^2	0,085	ad R^2	0,242
logLik	-361,325	logLik	-362,668	logLik	-384,708
AIC	5,295	AIC	5,272	AIC	5,599
BIC	5,546	BIC	5,460	BIC	5,808
$Q_1(\epsilon)$	0,625 0,429	$Q_1(\epsilon)$	0,501 0,479	$Q_1(\epsilon)$	0,334 0,564
$Q_4(\epsilon)$	1,118 0,891	$Q_4(\epsilon)$	0,709 0,950	$Q_4(\epsilon)$	3,315 0,507
$Q_1(\epsilon^2)$	1,660 0,198	$Q_1(\epsilon^2)$	0,032 0,857	$Q_1(\epsilon^2)$	0,385 0,535
$Q_4(\epsilon^2)$	4,005 0,405	$Q_4(\epsilon^2)$	2,473 0,649	$Q_4(\epsilon^2)$	6,657 0,155


Unter den Werten der Punktschätzungen stehen die t -Statistiken. Q_1 bezeichnet die Ljung-Box-Statistik für eine Verzögerte, Q_4 für vier Verzögerte. Der p -Wert ist unter den Wert der Ljung-Box-Statistik gesetzt.

Abbildung 2.5: Zustandswahrscheinlichkeiten MSI und MSIH



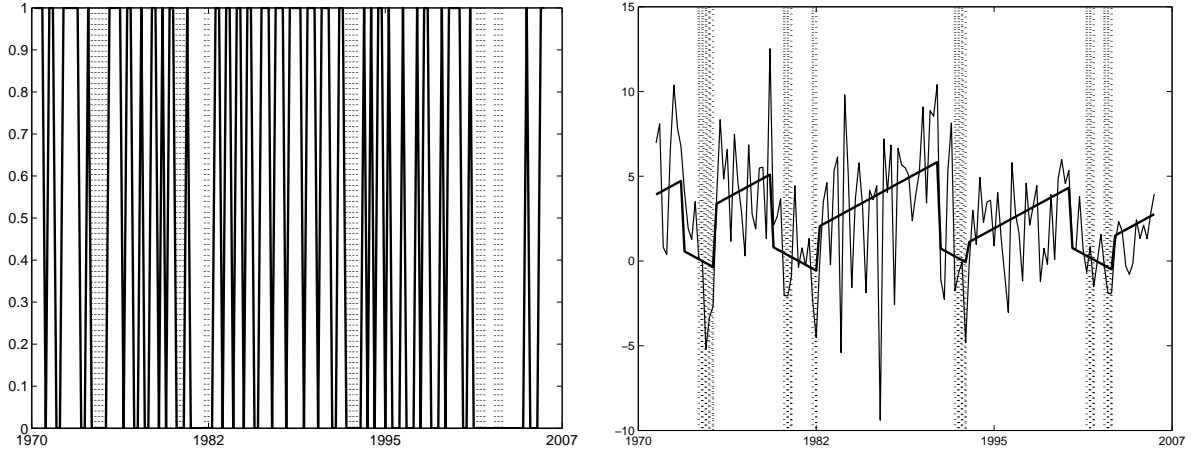
Links: Zustandswahrscheinlichkeiten des MSI-Modells; rechts: Zustandswahrscheinlichkeiten des MSIH-Modells;
jeweils gestrichelt: Rezessionen gemäß Bry-Boschan-Algorithmus

Abbildung 2.6: Zustandswahrscheinlichkeiten Bounce-Back-Modell



Gestrichelte Phasen: Rezessionen gemäß Bry-Boschan-Algorithmus

Abbildung 2.7: SETAR-Modell und DLR-Modell



Links: Zustände im SETAR-Modell; rechts: Regimedrift m_t des DLR-Modells und die ursprüngliche Zeitreihe y_t ; jeweils gestrichelt: Rezessionen gemäß Bry-Boschan-Algorithmus

2.5 Bayesianische Modellevaluation

2.5.1 Probleme frequentistischer Inferenz nicht-linearer Modelle

Maße zur Modellgüte wie das AIC oder BIC sind ad-hoc-Kriterien zur Beurteilung der Modellgüte und zur Modellselektion. Sie bieten also keinen formalen Modellvergleich bezüglich der Frage, ob nicht-lineare Modelle besser geeignet sind als das AR-Modell bzw. zu der Frage, welches Modell die deutschen Daten am besten beschreiben kann.

Hinsichtlich der Frage, ob nicht-lineare Modelle gegenüber linearen vorzuziehen sind, existieren verschiedene nicht-parametrische Tests, wie der BDS-Test (Brock et al. [1996]), die iid-Verhalten (H_0) gegen allgemeine Formen der Nicht-Linearität testen. Ferner werden Tests verwendet um explizite nicht-lineare Modelle gegen lineare zu testen, die in jenen genistet sind. Insbesondere gibt es Tests zu Schwellenwertmodellen und Markov-Switching-Modellen, deren Besonderheiten im Folgenden kurz skizziert werden.

Im SETAR-Modell ergibt sich die Nullhypothese als Restriktion auf den Parametern $\Theta_1 = \Theta_2$, wobei $\Theta_i = \{\mu_i, \phi_{i,1}, \dots, \phi_{i,4}, \sigma_i^2\}$ und $i \in \{1; 2\}$.²⁰ Für einen gegebenen bzw. bekannten Schwellenwert bieten sich nun verschiedene Standardtestverfahren an, um die Nullhypothese zu überprüfen, wie Likelihood-Ratio- (LR-), Lagrange-Multiplier- (LM-) oder Wald-Test, deren Teststatistiken asymptotisch bekannten χ^2 -Verteilungen folgen. Im SETAR wie auch im Floor-Ceiling-Modell sind die Schwellenwerte jedoch Parameter, die mitgeschätzt werden. Unter den

²⁰Im Floor-Ceiling-Modell ergeben sich folgende Restriktionen $\theta_1 = \theta_2 = 0$ und $\sigma_0^2 = \sigma_1^2 = \sigma_2^2$.

entsprechenden Nullhypothesen sind sie nicht identifiziert. Unter der Nullhypothese können diese Parameter also nicht konsistent geschätzt werden. Davies (1977,1987) fasst diesen Umstand unter das Problem der “Nuisance”-Parameter zusammen und bietet eine analytische Möglichkeit die obere Schranke des p -Wertes der LR-Teststatistik im Form des p -Wertes des Supremums (*sup*) der Teststatistik zu berechnen, die jedoch nur gilt, wenn die Likelihood im “Nuisance”-Parameter differenzierbar ist.²¹ Dies ist wie in Abschnitt 2.1.4 dargelegt bei Schwellenwerten in endlichen Stichproben mit einer endlichen Anzahl an Ausprägungen der Schwellenvariable nicht der Fall.

Neben der von Davies propagierten *sup*-Statistik verwenden Andrews und Ploberger (1994) die *avg*- und *exp*-Statistiken für die LR- wie auch die LM- und die Wald-Statistik. Sie geben die kritischen Werte der Verteilungen dieser Statistiken für den Fall an, dass die Schwellenvariable die Zeit ist (Strukturbruch). Für allgemeine Schwellenvariablen schlägt Hansen (1996) eine relativ einfaches Prozedere vor um die Verteilungen von (*sup*-, *avg*-, *exp*-) Wald- und LM-Statistiken per Simulation zu ermitteln.²² Die Simulation wird nötig, da die Teststatistik von der Schwellenvariable abhängt und somit für jede Schwellenvariable eine eigene Verteilung gilt.²³ Potter (1995) und Pesaran und Potter (1997) wenden das Vorgehen von Hansen an, um ihre Modelle gegenüber der Nullhypothese eines AR-Modells zu evaluieren.

Neben der Literatur zu Tests von Schwellenwertmodellen existieren Tests für die Nullhypothese linearer (genisteteter) Modelle gegen die Alternative im Form von Markov-Switching-Modellen, siehe Hansen (1992), Garcia (1998) oder Carrasco et al. (2005). Formuliert man die Nullhypothese als Restriktion, dass die Parameter der verschiedenen Zustände identisch sind, sind die Übergangswahrscheinlichkeiten bzw. die Parameter, die diese steuern, nicht identifiziert. Die Likelihoodfunktion ist allerdings differenzierbar in den Parametern der Markov-Kette. Der Ansatz von Davies (1977,1987) ist trotzdem nicht geeignet, obwohl er in der Literatur durchaus Verwendung findet, siehe dazu die Diskussion in Krolzig (1997). Die Regularitätsbedingungen des Davies-Test werden verletzt, da unter der Nullhypothese die Matrix der zweiten Ableitungen singulär ist.

Die Tests von Hansen (1992) und Garcia (1998) basieren auf Simulationen, die die wiederholte Schätzung unter der Gegenhypothese erfordern. Wegen des Problems lokaler Maxima, sind diese Simulationen mit entsprechendem Aufwand zu betreiben (für einen Simulationsschritt sollten die Schätzungen mehrfach unter der Gegenhypothese mit jeweils verschiedenen Startwerten

²¹Die Teststatistik wird gegeben den “Nuisance”-Parameter ermittelt und mit diesem indiziert. Eine obere Schranke herzuleiten entspricht damit der Verteilung des Supremums der Teststatistiken über den “Nuisance”-Parameter.

²²Die angesprochenen *sup*-, *avg*- und *exp*-Statistiken sind wie folgt zu verstehen. Die Teststatistiken sind Funktionen des Nuisanceparameters. Indem entweder das Supremum über alle möglichen Werte des Nuisanceparameters genommen wird oder alle möglichen Ausprägungen in eine Statistik zusammengefasst werden wie in den *avg*- und *exp*-Statistiken, wird eine Statistik ermittelt, die keine Funktion des Nuisanceparameters mehr ist.

²³Für Strukturbruchttests können allgemeine asymptotische Verteilungen angegeben werden, da die Zeit als Schwellenvariable eine einheitliche Form hat, siehe z.B. Andrews (1993).

errechnet werden). Schließlich formulieren Carrasco et al. (2005) einen asymptotisch optimalen Test, dessen Verteilung zwar auch simuliert werden muss, der aber nur Schätzungen unter der Nullhypothese benötigt. Allerdings nimmt der Rechenaufwand für Hypothesen, die unterstellen, dass mehrere Parameter gleichzeitig einem Markov-Prozess folgen, erheblich zu.

2.5.2 Marginale Likelihood

Der Überblick über verschiedene Testverfahren zeigt, dass die Inferenz zu nicht-linearen Modellen auch in frequentistischen Ansätzen einen erheblichen Rechen- bzw. Simulationsaufwand mit sich bringt. Ferner gibt es keine Möglichkeit zwischen verschiedenen nicht-linearen Modellen zu testen. Dieser Aspekt kann als Argument für die Verwendung Bayesianischer Inferenz gesehen werden, während besagter Rechenaufwand kaum als Argument dagegen genannt werden kann, da dieses Problem auch bei frequentistischen Ansätzen auftritt. Koop und Potter (1999) nennen außerdem die folgenden vier Punkte als Argumente für die Verwendung Bayesianischer Methoden:

- **Integration über Nuisance-Parameter:** Bei der Berechnung der Marginalen Likelihood werden Nuisance-Parameter per Integration beseitigt und beeinflussen die Inferenz nicht. Allerdings müssen dazu a priori Verteilungen der entsprechenden Parameter angenommen werden.
- **Ockhams Skalpell**²⁴: Durch die Berücksichtigung des Prior/Posterior Verhältnisses wird ein konsistenter Bestrafungsterm für zusätzlich Parameter berücksichtigt und somit eine sparsame Parametrisierung sichergestellt. Unter bestimmten Annahmen bezüglich der a priori Verteilungen entspricht das Prior/Posterior Verhältnis asymptotisch dem Bestrafungsterm des BIC, siehe Schwarz (1978).
- **Multimodale Likelihood:** Die Parameterunsicherheit, die durch lokale Maxima induziert wird, wird in frequentistischen Analysen vernachlässigt, während sie im Bayesianischen Ansatz durch die Integration über den gesamten Parameterraum Berücksichtigung findet.
- **Model Averaging:** Aus Marginalen Likelihoods können a posteriori Modellwahrscheinlichkeiten ermittelt werden, die es erlauben zum Beispiel die Vorhersagen verschiedener Modelle miteinander modellinherent zu verbinden.

Für den Modellvergleich der nicht-linearen Modelle des deutschen BIP-Wachstums sind die Eigenschaften von Ockhams Skalpell und der Umgang mit Nuisance-Parametern von großer Bedeutung. Letzteres ermöglicht schließlich auch den direkten Vergleich nicht genisteter Modelle.

²⁴Wilhelm von Ockham: englischer Philosoph und Theologe im 13./14. Jahrhundert. Das nach ihm benannte Wissenschaftsprinzip sagt aus, dass sparsamere Modelle reichhaltigeren bei ähnlichem Erklärungsgehalt vorzuziehen sind.

Der Modellvergleich mit Hilfe Bayesianischer Methoden fußt auf dem Konzept der Marginalen Likelihood, die als Modellevidenz der Daten zu interpretieren ist. Schließlich lassen sich aus den Werten der Marginalen Likelihood einer gegebene Anzahl von verschiedenen Modellen Wahrscheinlichkeitsaussagen über die relative Gültigkeit der Modelle treffen.²⁵ Je höher die Marginale Likelihood eines Modells ist, desto wahrscheinlicher ist es, dass die Daten aus diesem Modell im Vergleich zu den anderen Modellen stammen. Das Verhältnis der Werte der Marginalen Likelihoods wird als Bayes-Faktor bezeichnet. Um die absoluten Beträge dieser Verhältniszahlen zu interpretieren wird in der Regel die von Jeffreys (1961) dargestellte Skala verwendet.²⁶

Die Marginale Likelihood kann wie folgt dargestellt werden:

$$f(Y) = \frac{f(Y|\Theta) \cdot p(\Theta)}{p(\Theta|Y)}, \quad (2.22)$$

wobei $f(Y|\Theta)$ die gemeinsame Verteilung der Daten gegeben die Parameter, also die Likelihood, angibt, $p(\Theta)$ die a priori Verteilung (oder Prior) der Parameter und $p(\Theta|Y)$ die a posteriori Verteilung.

In Abschnitt 2.1 werden die Likelihoodfunktionen der verschiedenen Modelle diskutiert. Die a priori Verteilungen der Parameter wird in der Regel den Erfordernissen der Berechnung der a posteriori Verteilung angepasst. Im einfachen linearen Modell mit normalverteilten Fehlern ist die Berechnung der Marginalen Likelihood analytisch möglich, wenn als Prior eine gemeinsame Normal-Gamma-Verteilung für die Parameter der Mittelwertgleichung und die Varianz bzw. Präzision angenommen wird. Die a posteriori Verteilung ergibt sich dann ebenfalls als Normal-Gamma-Verteilung. Man spricht im Fall, dass a posteriori und a priori Verteilung aus der gleichen Familie stammen, von konjugierten Priorn. Für andere Prior im linearen Modell bzw. in den meistens nicht-linearen Modellen ist die a posteriori Verteilung in der Regel nur mit numerischen Methoden zu ermitteln.²⁷ Für viele Probleme bietet der Metropolis-Hastings-Algorithmus (in der Folge MH-Algorithmus) und seine Spezialform der Gibbs-Sampler eine Möglichkeit a posteriori Verteilungen der Parameter zu ermitteln. Im Folgenden wird der Gibbs-Sampler erläutert und seine Anwendung auf die nicht-linearen Modelle diskutiert.

2.5.3 Markov-Chain-Monte-Carlo-Methoden

In diesem Abschnitt wird der MH-Algorithmus und insbesondere der Gibbs-Sampler, der als Spezialfall des MH-Algorithmus angesehen werden kann,²⁸ im Hinblick auf ihre Anwendung auf die nicht-linearen Modelle der BIP-Wachstums dargestellt.

Der MH-Algorithmus geht auf die Arbeit von Metropolis et al. (1953) zurück und wurde durch

²⁵Siehe Koop (2003).

²⁶Die Skala von Jeffreys (1961) ist in Anhang A.3 dargestellt.

²⁷Siehe Koop (2003).

²⁸Siehe Chib (2001).

Hastings (1970) verallgemeinert. Es ist eine Markov-Chain-Monte-Carlo-Methode (MCMC). Dabei können durch ein iteratives Vorgehen Züge aus Verteilungen generiert werden, auch wenn kein direkter Pseudozufallszahlengenerator für diese Verteilung existiert bzw. die Wahrscheinlichkeitsdichtefunktion $\pi(\Theta)$ nur bis auf einen Proportionalitätsfaktor bekannt ist. Mit den Zügen aus der Zieldichte, dies kann zum Beispiel eine a posteriori Verteilung sein, können deren Momente berechnet werden. Das Vorgehen ist dabei wie folgt: aus einer Vorschlagsdichte $q(\Theta^{(j)})$ wird im $(j+1)$ -ten Zug ein Wert Θ' gezogen. Die Vorschlagsdichte kann vom vorherigen Zug (j) des MH-Algorithmus abhängen bzw. wenn $j = 0$ von den Startwerten. Es ist aber auch denkbar, dass die Vorschlagsdichte unabhängig von den vorhergehenden Zügen ist. Dann wird das Wahrscheinlichkeitsverhältnis $\alpha(\Theta^{(j)}, \Theta')$ zwischen dem Vorschlag und dem bisherigen Zug gebildet. Da der Proportionalitätsfaktor hier sowohl im Nenner als auch im Zähler auftritt, braucht er nicht bekannt sein.

$$\alpha(\Theta^{(j)}, \Theta') = \min \left[\frac{\pi(\Theta')q(\Theta', \Theta^{(j)})}{\pi(\Theta^{(j)})q(\Theta^{(j)}, \Theta')}, 1 \right]. \quad (2.23)$$

Dann wird aus einer $(0,1)$ -Gleichverteilung eine Zufallszahl u gezogen. Ist diese kleiner oder gleich α wird $\Theta^{(j+1)}$ gleich Θ' gesetzt. Im umgekehrten Fall wird $\Theta^{(j+1)}$ gleich $\Theta^{(j)}$ gesetzt. Das folgende Ablaufschema fasst den MH-Algorithmus zusammen:²⁹

(1) Startwert festlegen $\Theta^{(0)}$

(2) Zug aus der Vorschlagsdichte

$$\Theta' \sim q(\Theta^{(j)})$$

(3) Entscheidung

$$\Theta^{(j+1)} = \begin{cases} \Theta', & \text{wenn } u \leq \alpha(\Theta^{(j)}, \Theta'); \\ \Theta^{(j)}, & \text{sonst.} \end{cases}$$

(4) Wiederhole die Schritte (2) und (3) für $j = 1, 2, \dots, M$, wobei M abzüglich einer hinreichenden Anzahl von “burn-in”-Zügen die gewünschte Anzahl von Zügen aus $\pi(\Theta)$ ist.³⁰

Es ist generell wünschenswert eine Vorschlagsdichte zu finden, die der Zieldichte nahe kommt, um eine hohe Akzeptanzrate der Züge zu erzielen. Dabei sind übrigens auch Vorschlagsdichten denkbar, die nicht vom vorherigen Zug abhängen, so dass $q(\Theta^{(j)}) = q(\Theta^{(j+1)})$. Bei dieser Variante der Vorschlagsdichte ist zu beachten, dass die Vorschlagsdichte mehr Masse in den Flanken der Verteilung haben sollte als die Zieldichte. Für einige Probleme ist es aus numerischen Gründen bzw., weil keine adäquaten Vorschlagsdichten gefunden werden können, sinnvoll nicht alle Parameter in einem MH-Schritt zu ziehen, sondern Blöcke zu bilden, auf die dann gegenseitig bedingt

²⁹Die Darstellung lehnt sich an Chib (2001) an.

³⁰Der so genannte “burn-in” muss berücksichtigt werden um die Unabhängigkeit der Ergebnisse von den Startwerten sicherzustellen.

wird. Die so genannten “burn-in”-Züge werden zur Inferenz nicht herangezogen, da das Verfahren je nach den gewählten Startwerten und dem vorliegenden Problem eine gewisse Anzahl an Zügen braucht um zur stationären Verteilung der Markov-Kette zu konvergieren.

Ein Spezialfall des Multi-Block-MH-Algorithmus ist der Gibbs-Sampler. Er ergibt sich, wenn die bedingten Verteilungen der einzelnen Blöcke geeignet sind, direkt aus diesen Züge zu generieren (die bedingten Verteilungen sind vollständig bekannt). Die Idee des Gibbs-Samplers wie des Multi-Block-MH-Algorithmus insgesamt ist durch das iterative Ziehen aus den bedingten Verteilungen, deren Bedingungen durch die Züge aus den anderen Blöcken jeweils aktualisiert werden, Züge aus der gemeinsamen Verteilung aller Blöcke bzw. Parameter zu generieren. Es sei erwähnt, dass es möglich ist im Multi-Block-MH-Algorithmus nur einzelne Blöcke mit den Gibbs-Sampler zu ziehen. Dieser Fall wird in der Literatur auch als “MH-within-Gibbs”-Algorithmus bezeichnet.³¹

Unterstellt man K Blöcke von Parametern lässt sich das Ablaufschema des Gibbs-Samplers wie folgt darstellen:³²

$$(1) \text{ Startwert } \Theta^{(0)} = \left\{ \theta_1^{(0)}, \theta_2^{(0)}, \dots, \theta_K^{(0)} \right\}$$

(2) Ziehe

$$\theta_1^{(j+1)} \text{ aus } \pi \left(\theta_1 | \theta_2^{(j)}, \theta_3^{(j)}, \dots, \theta_K^{(j)} \right)$$

$$\theta_2^{(j+1)} \text{ aus } \pi \left(\theta_2 | \theta_1^{(j+1)}, \theta_3^{(j)}, \dots, \theta_K^{(j)} \right)$$

$$\theta_3^{(j+1)} \text{ aus } \pi \left(\theta_3 | \theta_1^{(j+1)}, \theta_2^{(j+1)}, \dots, \theta_K^{(j)} \right)$$

\vdots

$$\theta_K^{(j+1)} \text{ aus } \pi \left(\theta_K | \theta_1^{(j+1)}, \theta_2^{(j+1)}, \dots, \theta_{K-1}^{(j+1)} \right)$$

(3) Wiederhole den Schritt (2) für $j = 1, 2, \dots, M$, wobei M abzüglich einer hinreichenden Anzahl von “burn-in”-Zügen die gewünschte Anzahl von Zügen aus $\pi(\Theta)$ ist.

Latente Variablen wie die Zustandsvariable in Markov-Switching-Modellen werden in diesem Rahmen als “Parameter” aufgefasst und mitgezogen, vgl. Tanner und Wong (1987). Für den Multi-Block-MH-Algorithmus müssen die einzelnen Züge in Schritt (2) des Gibbs-Samplers durch die Schritte (2) und (3) des MH-Algorithmus ersetzt werden, wobei die vollständig bedingten Verteilungen nun als Zieldichten fungieren.

Durch den MH-Algorithmus bzw. den Gibbs-Sampler stehen Methoden zur Verfügung Züge aus einer Verteilung zu generieren, deren Verteilung bis auf einen Proportionalitätsfaktor bekannt bzw. deren normalisierende Konstante unbekannt ist, wie dies bei a posteriori Verteilungen

³¹Siehe z.B. Chib und Greenberg (1995).

³²Die Darstellung lehnt sich an Chib (2001) an.

nicht-linearer Modelle häufig der Fall ist. Die Wahrscheinlichkeitsdichtefunktion der a posteriori Verteilung für bestimmte Werte der Parameter, wie es für die Berechnung der Marginalen Likelihood gemäß Gleichung 2.22 notwendig ist, lässt sich in einem solchen Fall allerdings nicht direkt berechnen. Im Rahmen des Gibbs-Samplers schlägt Chib (1995) ein Verfahren vor, dass die blockweise Betrachtung für die Berechnung der a posteriori Verteilung an der Stelle der Bayes-Schätzung übernimmt.³³ Unterstellt man K Blöcke der Parameter $\Theta = \{\theta_1, \dots, \theta_K\}$ wird die a posteriori Verteilung an der Stelle Θ^* wie folgt faktorisiert:

$$p(\Theta^*|Y) = p(\theta_1^*|\theta_2^*, \dots, \theta_K^*, Y) \cdot p(\theta_2^*|\theta_3^*, \dots, \theta_K^*, Y) \cdot \dots \cdot p(\theta_K^*|Y), \quad (2.24)$$

wobei die vollständig bedingten Dichten $p(\theta_k^*|\Theta_{K-k}^*, Y)$ in analytischer Form vorliegen müssen.³⁴ Für die Ermittlung der Marginalen Likelihood wird die a posteriori Verteilung an der Stelle des Bayes-Schätzers evaluiert. Ausdrücke wie $p(\theta_K^*|Y)$ werden per Integration über die vollständig bedingten Verteilungen berechnet. Dabei gilt allgemein

$$p(\theta_K^*|Y) = \int \dots \int p(\theta_K^*|\theta_1, \dots, \theta_{K-1}, Y) p(\theta_1, \dots, \theta_{K-1}, Y) d\theta_1 \dots d\theta_{K-1}. \quad (2.25)$$

Da das Integral in Gleichung 2.25 in der Regel analytisch nicht lösbar ist, wird es mit dem Gibbs-Sampler numerisch approximiert:

$$p(\theta_K^*|Y) = \frac{1}{M} \sum_{j=1}^M p(\theta_K^*|\theta_1^{(j)}, \dots, \theta_{K-1}^{(j)}, Y), \quad (2.26)$$

wobei hier wiederum j einen Zug bei insgesamt M Zügen aus dem Gibbs-Sampler bezeichnet. Zur Berechnung des Ausdrucks 2.26 können die Gibbs-Züge verwendet werden, die auch zur Berechnung der Bayes-Schätzung genutzt werden. Für die Berechnung des nächsten Ausdrucks auf der rechten Seite der Gleichung 2.24 $p(\theta_{K-1}|\theta_K, Y)$ wird in die Bedingung für θ_K die Bayes-Schätzung θ_K^* eingesetzt. Für die Berechnung bzw. Approximation des resultierenden Integrals

$$p(\theta_{K-1}^*|\theta_K^*, Y) = \int \dots \int p(\theta_{K-1}^*|\theta_1, \dots, \theta_{K-2}, \theta_K^*, Y) p(\theta_1, \dots, \theta_{K-2}|Y) d\theta_1 \dots d\theta_{K-2}. \quad (2.27)$$

können ebenfalls die bereits vorliegenden Züge des Gibbs-Samplers verwendet werden. Wenn allerdings latente Zustandsvariablen wie im MS-Modell eine Rolle spielen, über die ebenfalls integriert werden muss, um zur a posteriori Verteilung der Parameter zu gelangen, muss das Gibbs-Sampling wiederholt werden mit dem Unterschied, dass nicht mehr alle Variablen gezogen

³³Im Rahmen des Gibbs-Samplers kann der Mittelwert der Simulationen als Bayes-Schätzer verwendet werden. Entsprechend des schwachen Gesetz der großen Zahl handelt es sich dann beim Mittelwert um einen Schätzer des Erwartungswerts der posteriori Verteilung.

³⁴Ist dies nicht der Fall und die bedingten Züge wurden entsprechend mit dem MH-Algorithmus ermittelt, dann bieten Chib und Jeliazkov (2001) ein weitergehendes Verfahren zur Berechnung der a posteriori Verteilung.

werden; das Ziehen des K-ten Blocks fällt weg. Das entsprechende Integral umfasst ebenfalls die Zustandsvariable $\{s_t\}_{t=1}^T$:

$$p(\theta_{K-1}^* | \theta_K^*, Y) = \int \dots \int p(\theta_{K-1}^* | \theta_1, \dots, \theta_{K-2}, \theta_K^*, \{s_t\}_{t=1}^T, Y) p(\theta_1, \dots, \theta_{K-2}, \{s_t\}_{t=1}^T | Y) d\theta_1 \dots d\theta_{K-2} d\{s_t\}_{t=1}^T. \quad (2.28)$$

und wird an der Stelle des Bayes-Schätzers über folgenden Ausdruck approximiert

$$p(\theta_{K-1}^* | \theta_K^*, Y) = \frac{1}{M} \sum_{j=1}^M p(\theta_{K-1}^* | \theta_K^*, \theta_1^{(j)}, \dots, \theta_{K-1}^{(j)}, \{s_t\}_{t=1}^T{}^{(j)}, Y). \quad (2.29)$$

Im Rahmen des Gibbs-Sampling werden latente Zustandsvariablen wie $\{s_t\}_{t=1}^T$ als fehlende Daten interpretiert und augmentiert, also mitgezogen.³⁵ Ähnlich wie bei den Parametern ergibt der Gibbs-Sampler Züge aus $f(\{s_t\}_{t=1}^T | Y)$. Für die Berechnung der bedingten Verteilungen in Gleichung 2.28 bzw. 2.29 bedarf es aber Züge aus $f(\{s_t\}_{t=1}^T | Y, \theta_K)$, was durch das Weglassen des Ziehens aus dem K-ten Block und dem Einsetzen von $\hat{\theta}_K$ erreicht wird. Beim nächsten Schritt wird der Gibbs-Sampler dann um den (K-1)-ten Block verkürzt usw., so dass der Gibbs-Sampler bzw. seine verkürzten Formen K mal durchlaufen werden muss.

2.5.4 Berechnen der Marginale Likelihood

In diesem Abschnitt werden die im vorherigen Abschnitt diskutierten Methoden zur Berechnung der Marginalen Likelihood für die unterschiedlichen Modelle konkretisiert. Die Marginale Likelihood setzt sich aus dem Likelihood-Wert an der Stelle der Bayes-Schätzung, dem Wert der a priori Verteilung und der a posteriori Verteilung jeweils an der Stelle der Bayes-Schätzung zusammen. Die Likelihoodfunktionen wurden in Abschnitt 2.1 diskutiert. An dieser Stelle werden a priori und a posteriori Verteilungen der jeweiligen Modelle bzw. die zur Berechnung der a posteriori Verteilungen notwendigen Gibbs-Sampler diskutiert.

AR-Modell

Die Parameter werden in zwei Blöcke unterteilt. Der Interzept μ und die autoregressiven Parameter $\{\phi_\ell\}_{\ell=1}^4$ bilden einen Block und Varianz bzw. ihre Inverse, die Präzision τ , bilden den zweiten. Für den ersten Block wird a priori eine multivariate Normalverteilung unterstellt. Für den zweiten Block wird a priori eine Gamma-Verteilung angenommen. Die resultierende gemeinsame a posteriori Verteilung kann nicht analytisch ermittelt werden.³⁶ Es ergeben sich jedoch

³⁵Siehe Tanner und Wong (1987) und im Rahmen des Markov-Switching-Modells Albert und Chib (1993b) bzw. Carter und Kohn (1994) oder Shephard (1994).

³⁶Dies wäre nur bei einem Normal-Gamma-Prior möglich, wenn also die Varianz der Mittelwertparameter a priori von der Verteilung der Fehlervarianz abhinge. Auf diese Wahl von a priori Verteilungen wurde verzichtet, um eine bessere Vergleichbarkeit zu erhalten. Bei heteroskedastischen Modellen wie dem MSIH-Modell oder dem Floor-Ceiling-Modell sind die hier gewählten a priori Verteilungen leichter handhabbar.

bekannte bedingt Verteilungen: eine multivariate Normalverteilung für den ersten Block bedingt auf die Präzision und die Daten sowie eine Gammaverteilung für die Präzision bedingt auf die Mittelwertparameter und die Daten. Mit Hilfe des Gibbs-Samplers kann der Wert der a posteriori Verteilung an der Stelle der Bayes-Schätzung ermittelt werden.³⁷

MS-Modelle

Gegeben die Zustandsvariablen $\{s_t\}_{t=1}^T$ sind die Parameter μ_i , $\{\phi_{i,\ell}\}_{\ell=1}^4$ und im Falle des Bounce-Back-Modells γ Parameter eines linearen Regressionsmodells und werden analog zum AR-Modell zu einem Block zusammengefasst. Entsprechend wird wiederum a priori eine multivariate Normalverteilung unterstellt, wobei die Dimension des Vektors bzw. der Varianz jeweils von der Art des MS-Modells abhängt. Im MSA-Modell handelt es sich um eine 9-dimensionale im MSI-Modell um eine 6-dimensionale Verteilung. Die Varianz bzw. Präzision wird analog zum AR-Modell einem zweiten Block zugeordnet. Im Falle der heteroskedastischen Modelle MSAH und MSIH sind beide Varianzparameter in diesem Block. Es werden jeweils Gamma-Prior für die Präzisionen angenommen. Gegeben $\{s_t\}_{t=1}^T$ sind die Übergangs- bzw. Bleibewahrscheinlichkeiten p_{11} und p_{22} unabhängig von allen anderen Parametern und können daher einem beliebigen Block zugeordnet werden. Für beide Parameter wird jeweils a priori eine Beta-Verteilung angenommen. Durch diese Wahl der Prior entstammen die vollständig bedingten Verteilungen der Blocks dem gleichen Verteilungstyp wie die Prior-Verteilung.

Im Gibbs-Sampler werden neben den Parametern auch die Zustandsvariable $\{s_t\}_{t=1}^T$ gezogen. Es gibt zwei Ansätze aus der vollständig bedingte Verteilung von $\{s_t\}_{t=1}^T$ zu ziehen: den Single-Move-Sampler von Albert und Chib (1993b) sowie den Multi-Move-Sampler von Carter und Kohn (1994) bzw. Shephard (1994). Letzterer wird wegen seiner besseren Konvergenzeigenschaften in der Regel vorgezogen. Der Multi-Move-Sampler ist in Appendix A.2 beschrieben.

Basierend auf der eben beschriebenen Wahl der a priori Verteilungen wird die a posteriori Verteilung mit Hilfe des Verfahrens von Chib (1995) berechnet. Die Likelihood kann mit dem Hamilton-Filter errechnet werden, so dass alle Komponenten der Marginalen Likelihood gemäß Gleichung 2.22 vorliegen.

SETAR-Modell

Im SETAR-Modell existiert ein Schwellenparameter r sowie ein Parameter q , der die Verzögerung der Schwellenvariable steuert. Gegeben diese beiden Parameter entspricht das SETAR-Modell einem bzw. zwei linearen Regressionsmodellen, deren Marginale Likelihood analog zum AR-Modell berechnet werden kann. Bedingt auf r und q werden per Gibbs-Sampling analog zum

³⁷Die expliziten Gibbs-Sampler sowie die vollständig bedingten Verteilungen, auf denen der Gibbs-Sampler fußt, werden für alle Modelle in Appendix A.2 angegeben. Dort werden auch die Hyperparameter der a priori Verteilungen angegeben.

AR-Modell Werte für die a posteriori Verteilungen und die Likelihood ermittelt. Dies wird für alle möglichen Werte von r und q gemacht. Folglich wird für jedes mögliche Wertepaar von r und q der Gibbs-Sampler zur entsprechend bedingten Schätzung erneut herangezogen. Bezogen auf den Parameter q wird a priori angenommen, dass dieser die Werte eins bis vier annehmen kann. Legt man a priori auf diese vier Werte die gleiche Wahrscheinlichkeit, kann der Parameter “heraus gemittelt” werden, indem die Marginalen Likelihoodwerte der vier entsprechenden linearen Modelle errechnet und summiert sowie durch vier geteilt werden, was der Berücksichtigung des Priors von q in Form einer diskreten Gleichverteilung entspricht.

Die resultierenden Werte sind immer noch bedingt auf r , wobei r ebenfalls nicht innerhalb des Gibbs-Samplers berücksichtigt wird, sondern im Anschluss aus den Ergebnissen des Gibbs-Samplers heraus integriert wird.³⁸ Analog zu der Anzahl der Ausprägungen der Schwellenvariable existiert eine endliche Anzahl von Intervallen von r , für die die zuvor beschriebenen Werte berechnet werden müssen. Die Intervalle liegen jeweils zwischen zwei aufeinander folgende Ordnungsstatistiken der Schwellenvariable, in welchem beliebige Werte von r den gleichen Wert der Likelihood ergeben, so dass die Likelihood nur für einen Wert des Intervalls von r korrespondierend zu den Ausprägungen der Schwellenvariable berechnet werden muss. Unterstellt man nun a priori für r eine stetige Gleichverteilung zwischen einem minimalen und maximalen Wert der Schwellenvariable, wird diese endliche Anzahl von Werten mit der jeweiligen a priori Wahrscheinlichkeit, die der Länge des Intervalls zwischen zwei aufeinanderfolgenden Ordnungsstatistiken der Schwellenvariable entspricht, multipliziert und aufsummiert. Man erhält somit letztlich die Marginale Likelihood des SETAR-Modells. Es sei darauf hingewiesen, dass die Marginale Likelihood des hier vorliegenden SETAR-Modells unter der hier besprochenen Berücksichtigung der Schwellenvariablen bei der Wahl eines Normal-Gamma-Priors analytisch berechenbar wäre, siehe Koop und Potter (1999).

Floor-Ceiling-Modell

Für das Floor-Ceiling-Modell gilt ein ähnliches Vorgehen wie für das SETAR-Modell bezüglich des Schwellenparameters r_F . Es werden zuerst Werte, gegeben die möglichen Ausprägungen von r_F , errechnet und anschließend wird über r_F integriert. Die jeweils auf r_F bedingten Werte werden jeweils durch einen erneuten Durchlauf des Gibbs-Samplers ermittelt. Die Mittelwert- und Varianzparameter gegeben r_F sind analog zu den Mittelwert- und Varianzparameter z.B. des MSIH-Modells zu behandeln. Es werden im Wesentlichen die gleichen a priori Verteilungen angenommen, und die Herleitung der vollständig bedingten Verteilungen ist identisch. Wegen der besonderen Form der Heteroskedastie wäre für dieses Modell eine analytische Herleitung der Marginalen Likelihood im Vergleich zum SETAR-Modell nicht möglich.

³⁸Siehe Koop und Potter (1999).

Tabelle 2.4: Marginale Likelihood

	AR	MSA	MSAH	MSI	MSIH	BB	SETAR	FC	DLR
1.	-393,75	-402,87	-405,04	-393,51	-394,36	-396,34	-406,72	-388,33	-393,70
2.	-392,21	-401,50	-403,10	-392,16	-392,34	-394,85	-403,57	-388,87	-393,74
3.	-393,76	-403,00	-405,79	-393,87	-395,07	-396,51	-406,63	-390,76	-392,30
4.	-392,13	-400,00	-401,99	-391,59	-392,35	-393,97	-403,57	-385,44	-392,22
5.	-390,59	-398,20	-399,78	-390,14	-390,18	-392,67	-400,41	-382,43	-391,91
6.	-392,15	-400,15	-401,78	-391,78	-392,98	-394,14	-403,48	-387,72	-392,60
7.	-390,16	-395,99	-398,00	-389,02	-389,77	-391,35	-399,61	-383,53	-393,97
8.	-388,61	-394,69	-395,56	-387,67	-387,59	-389,62	-396,48	-384,54	-391,39
9.	-390,17	-396,21	-398,58	-389,30	-390,26	-391,38	-399,55	-385,97	-393,18

DLR-Modell

Gegeben die Zustandsvariable $\{r_t\}_{t=1}^T$ wird mit Hilfe des von Chib (1995) beschriebenen Verfahrens und des in Appendix A.2 erläuterten Gibbs-Sampler eine entsprechend bedingte a posteriori Verteilung ermittelt. Ebenfalls bedingt werden die Likelihood sowie der Wert der a priori Verteilung an der Stelle des Bayes-Schätzers ermittelt. Die Marginale Likelihood wird dann dadurch gewonnen, dass der resultierende Ausdruck über $\{r_t\}_{t=1}^T$ integriert wird. Dazu wird der in DeJong et al. (2005) beschriebene Importance-Sampler verwendet, der ebenfalls in Anhang A.2 erläutert wird. Für jeden Zug von $\{r_t\}_{t=1}^T$ aus dem Importance-Sampler wird eine Bayes-Schätzung zur Berechnung der auf $\{r_t\}_{t=1}^T$ bedingten Likelihood an der Stelle der entsprechenden Schätzung durchgeführt sowie der korrespondierende Wert der a posteriori Verteilung berechnet.³⁹

2.5.5 Ergebnisse

Tabelle 2.4 gibt die Marginale Likelihood der Modelle für neun verschiedene Prior-Szenarien wieder. Die Unterscheidungsmerkmale der Prior-Szenarien werden in Tabelle A.1 dargelegt. Für alle Modelle werden 10.000 Gibbs-Iterationen durchgeführt, wobei die ersten 2000 Züge nicht zur Inferenz herangezogen werden. Aus dem Importance-Sampler des DLR-Modells werden 1000 Züge gemacht. In allen Fällen weist das Floor-Ceiling-Modell die höchsten Werte auf, wobei die Differenzen zum jeweils zweitbesten Modell im Sinne der Skala von Jeffreys (1961) als stark oder sehr stark zu bezeichnen sind. Die Wahl des zweitbesten Modells hängt von den a priori Annahmen ab und Differenzen, die eine starke Evidenz manifestieren, existieren nicht. Für sieben der neun Szenarien (1-2; 4-7 und 9) weist das MSI-Modell die zweithöchste Marginale Likelihood auf allerdings mit durchweg sehr geringen Differenzen zum AR-, MSIH- und DLR-Modell. Im 3. Fall ist das DLR-Modell das zweitbeste und hat zum drittbesten Modell einen Differenz von

³⁹Für jede der Bayes-Schätzungen muss der Gibbs-Sampler erneut durchlaufen werden.

1,56, während die Differenz zum besten Modell 1,54 beträgt. Im 8. Szenario ist das MSIH das zweitbeste. Allerdings mit sehr geringem Abstand zum MSI-Modell. Die Modelle mit einer hohen Anzahl autoregressiver Koeffizienten, MSA, MSAH und SETAR, schneiden alle sehr schlecht ab. Das Bounce-Back-Modell liegt stets vor diesen Modellen, aber ist stets schlechter als AR oder MSI.

Die Auswertung der Marginalen Likelihoods zeigt, dass das Floor-Ceiling-Modell die Wachstumsraten des deutschen BIP am besten erklären kann. Eine darüber hinausgehende Reihenfolge der Modelle kann grob in Form von zwei Gruppen dargestellt werden. Zum einen die Modelle AR, MSI, MSIH und DLR, die hinter dem Floor-Ceiling-Modell kommen, und untereinander in keine eindeutige Reihenfolge gebracht werden können. Hinter dieser Gruppe kommen dann die Modelle MSA, MSAH und SETAR.⁴⁰

2.6 Prognosegüte

In diesem Abschnitt werden die Prognoseeigenschaften der zuvor dargestellten Modelle diskutiert. Die Fähigkeit eines Modells Prognosen zu erstellen wird in der ökonomischen Literatur als Hinweis für die Güte des Modells oder der damit verbundenen Hypothese aufgefasst.⁴¹ Um die Prognoseeigenschaften der Modelle zu evaluieren wird ein Prognoseexperiment der folgenden Form durchgeführt. Die letzten 40 Beobachtungen der Stichprobe werden mit den Modellen prognostiziert. Der Stützzeitraum, aus dem die ML-Schätzung der Parameter der Modelle stammen, umfasst im ersten Schritt die Stichprobe minus der letzten 40 Beobachtungen. Ausgehend von diesem Stützzeitraum werden Ein-Schritt-, Zwei-Schritt- und Vier-Schritt-Prognosen gewonnen. Im Anschluss wird der Stützzeitraum um eine Beobachtung erweitert und die nächsten Prognosen werden gewonnen. Dies wird solange fortgesetzt, bis 40 Ein-Schritt-Prognosen ermittelt worden sind. Es werden sowohl Punkt- als auch Intervallprognosen ermittelt, um zusätzlich zu überprüfen, ob das Prognosemodell die Unsicherheit der Prognose richtig erfasst.

2.6.1 Prognose in nicht-linearen Modellen

Unterstellt man eine quadratische Verlustfunktion, kann man zeigen, dass der bedingte Erwartungswert die beste Vorhersage liefert. Als Prognose wird also

$$y_{t+h}^f = E(y_{t+h}|I_t)$$

⁴⁰Für US-Daten gibt es ebenfalls keine eindeutige Evidenz für das SETAR-Modell. Potter (1995) berichtet verschiedene Tests mit der Nullhypothese eines linearen Modells, die jeweils zu unterschiedlichen Ergebnissen führen. Cancelo und Mourelle (2005) nehmen die Null eines linearen Modells gegenüber einer Verallgemeinerung des SETAR-Modells für US-Daten an.

⁴¹Siehe z.B. die einleitende Diskussion von Diebold und Lopez (1996).

verwendet, wobei h den Prognosehorizont bezeichnet und I_t die Informationsmenge zum Zeitpunkt t . Die Berechnung des bedingten Erwartungswertes für beliebige Prognosehorizonte im AR-Modell wie auch, Dank des Hamilton-Filters, in den Markov-Switching-Modellen ist analytisch möglich. Gleiches gilt auch für die Prognoseintervalle beider Modelltypen. Bezogen auf die Modelle mit Schwellenwerten ist die analytische Herleitung nur für die Perioden trivial, in denen die Schwellenvariable beobachtbar ist. Darüber hinaus wird die Berechnung der Punktprognosen sowie insbesondere der Prognoseunsicherheit bzw. der Prognoseintervalle nicht trivial bzw. allgemein nicht analytisch lösbar.⁴²

Clements und Smith (1997,1999) zeigen, dass Monte-Carlo-Methoden zu hinreichend guten Approximationen für Punkt- und Intervallprognosen führen. Dieser Ansatz wird auch in dieser Arbeit verfolgt. Für das SETAR-, das Floor-Ceiling und das DLR-Modell werden jeweils 10.000 Verläufe vier Schritte voraus für jeden der 40 Prognoseausgangspunkte simuliert. Daraus werden als arithmetisches Mittel die Punktprognosen und aus den empirischen Verteilungsfunktionen die Intervallprognosen gewonnen.

2.6.2 Evaluation von Punktprognosen

Als Prognosefehler wird die Abweichung der Punktprognose von der Realisation bezeichnet, $\hat{e}_t = y_t - y_t^f$. Ein populäres Mittel die Prognosegüte mehrerer Punktprognosen eines Modelles zu erfassen und mit anderen vergleichbar zu machen ist der mittlere quadratische Fehler (quadratische Verlustfunktion) kurz MSE für mean squared error. Im Rahmen dieser Arbeit wird diese Form der Verlustfunktion betrachtet.⁴³

An den Vergleich der MSE der Prognosen verschiedener Modelle schließt sich die Frage an, ob die eventuell auftretenden Unterschiede statistisch signifikant sind. In Diebold und Mariano (1995) wird ein zweiseitiger asymptotischer Test, der für allgemeine Verlustfunktionen formuliert ist, vorgeschlagen, der die Nullhypothese überprüft, dass zwei Prognosemodelle eine identische Prognosegüte haben. Für eine quadratische Verlustfunktion ergibt sich die folgende Teststatistik:

$$DM = \frac{\frac{1}{N} \sum_t d_t}{\sqrt{\frac{1}{N} \hat{\sigma}_d^2}}, \quad (2.30)$$

wobei $d_t = \hat{e}_{i,t}^2 - \hat{e}_{j,t}^2$ und $\hat{e}_{i,t}$ den Prognosefehler von Modell i zum Zeitpunkt t bezeichnet. N bezeichnet den Umfang der Prognosestichprobe bzw. die Anzahl der Prognosen. Die Varianz der Differenzen $\hat{\sigma}_d^2$ wird bei Einschnittprognosen über die einfache Stichprobenvarianz geschätzt. Sofern der Prognosehorizont größer als eins ist, wird bei der Berechnung die mögliche Autokorrelation der Prognosefehler über den Ansatz von Newey und West (1987) berücksichtigt. Asymptotisch folgt DM einer Normalverteilung. In kleinen Stichproben zeigen Harvey et al. (1997),

⁴²Siehe Clements und Smith (1997,1999) oder Clements und Krolzig (1998).

⁴³Es sind daneben noch andere Verlustfunktionen denkbar wie absolute Abweichungen oder unterschiedliche Gewichtungen der Richtungen der Abweichungen, die je nach Art des ökonomischen Problems vorzuziehen sind.

dass die t -Verteilung zur Ermittlung der kritischen Werte jedoch bessere Eigenschaften hat als die Normalverteilung. Diese Verteilungen sind nur gültig, sofern die beiden zu vergleichenden Modelle nicht genistet sind. Außerdem macht bei genisteten Modellen nur ein einseitiger Test Sinn, siehe McCracken (1999).⁴⁴

Alternativ zum Diebold-Mariano-Test auf gleiche Vorhersagegüte wird der einseitige Test von Harvey et al. (1998) verwendet, dessen Nullhypothese besagt, dass die Prognosen des Modells i die Prognosen des Modells j umfassen, das Modell j also keine zusätzliche Information bereit hält. Die korrespondierende Teststatistik hat die folgende Form:

$$ENC = \frac{\frac{1}{N} \sum_t h_t}{\sqrt{\frac{1}{N} \hat{\sigma}_h^2}}, \quad (2.31)$$

wobei $h_t = (\hat{e}_{i,t})(\hat{e}_{i,t} - \hat{e}_{j,t})$. Asymptotisch sind sowohl DM als auch ENC normalverteilt, wobei in kleinen Stichproben auch für ENC die Verwendung der t -Verteilung zu empfehlen ist. Dies gilt jedoch nur, wenn Modell i und j nicht ineinander genistet sind. Clark und McCracken (2001) stellen fest, dass in diesem Fall die Verteilung unter der Nullhypothese anders lauten muss, da bei genisteten Modellen asymptotisch beide Modelle identische Prognosen machen. Clark und McCracken (2001) tabellieren die kritischen Werte des ENC -Test für genistete Modelle für Ein-Schritt-Prognosefehler. Ferner gelten die Werte für lineare Modelle, so dass diese nicht direkt auf den Vergleich z.B. zwischen AR- und MSI-Modell übertragen werden können.

Clark und West (2007) schlagen für einen Test auf gleiche Prognosegüte genisteter Modelle folgende Teststatistik vor:

$$CW = \frac{\frac{1}{N} \sum_t cw_t}{\sqrt{\frac{1}{N} \hat{\sigma}_{cw}^2}}, \quad (2.32)$$

wobei $cw_t = \hat{e}_{i,t}^2 - (\hat{e}_{j,t} - (\hat{y}_{i,t} - \hat{y}_{j,t}))^2$, für deren Verteilung die Normalverteilung insbesondere in kleinen Stichproben eine hinreichend gute Approximation ist.⁴⁵ In diesem Fall steht i für das restringierte und j für das unrestringierte Modell. Tatsächlich entspricht CW der Teststatistik ENC für nicht-genistete Modelle. Die Punktprognosen genisteter Modelle werden mit dem CW -Test verglichen, während für nicht-genistete Modelle der DM -Test sowie der ENC -Test zur Anwendung kommen.⁴⁶

⁴⁴Unter der Hypothese, dass das geringer parametrisierte Modell das wahre Modell ist, sind die zusätzlichen Parameter null und würden bei konsistenten Schätzmethoden asymptotisch auch so geschätzt, so dass asymptotisch beide Modelle identische Vorhersagen machen. McCracken (1999) tabelliert auch die Werte der asymptotischen Verteilung der DM -Statistik für Ein-Schritt-Prognosen. An dieser Stelle werden diese Werte jedoch nicht herangezogen, da auch Zwei- und Vier-Schritt-Prognosen an dieser Stelle Verwendung finden.

⁴⁵Die asymptotische Verteilung folgt keiner Normalverteilung.

⁴⁶Clark und West (2007) diskutieren ihre Ergebnisse vor dem Hintergrund linearer Modelle. Die Ergebnisse von Clark und West (2007) werden an dieser Stelle als Approximation angewendet. Die Inferenz zum Vergleich von Prognosen aus nicht-linearen Modellen und genisteten linearen Modellen ist Gegenstand zukünftiger Forschung.

2.6.3 Evaluation von Intervallprognosen

Intervallprognosen reflektieren, dass Prognosen stets mit Unsicherheit einhergehen. Die Punktprognose ist in der Regel ein bedingter Erwartungswert. In der Intervallprognose wird zusätzlich die Streuung im Prognosemodell berücksichtigt und Intervalle mit nominellen Überdeckungswahrscheinlichkeiten angegeben. Mit der Evaluation der Intervallprognosen kann überprüft werden, ob das Prognosemodell die Unsicherheit der Prognose und die Streuung des Prognosefehlers gut erfasst. Von besonderem Interesse sind Intervallprognosen und ihre Evaluation angesichts möglicher Heteroskedastie. Dabei geht es um die Frage, ob das Prognosemodell volatile von weniger volatilen Zeiten richtig diskriminieren kann.

In diesem Kontext werden drei Testideen von Christoffersen (1998) und Wallis (2003) diskutiert. Während Christoffersen (1998) LR-Tests vorschlägt, basieren die Tests in Wallis (2003) auf dem Anpassungstest von Pearson. An dieser Stelle werden die Tests von Wallis (2003) dargestellt, die jeweils auf die Intervallprognosen der verschiedenen Modelle des deutschen BIP-Wachstums angewendet werden.

- **Test auf unbedingte korrekte Überdeckung:** Die Idee dieses Tests ist die Überprüfung, ob die nominelle Überdeckungswahrscheinlichkeit des Prognoseintervalls p_N mit den tatsächlichen Realisationen übereinstimmt; bei einem Prognoseintervall von 90 % sollte auch ein entsprechender Anteil der Realisationen in diesen liegen.⁴⁷ Von der Anzahl an Prognoseintervallen N wird die Menge bestimmt, in die die Realisation fällt, N_1 , und als Komplement die Anzahl der Fälle, in der die Realisation außerhalb des Prognoseintervalls liegt, N_2 . Den tatsächlichen Treffern steht die erwartete Anzahl von Treffern gegeben die nominelle Überdeckungswahrscheinlichkeit gegenüber $\hat{N}_1 = p_N \cdot N$ bzw. $\hat{N}_2 = (1 - p_N) \cdot N$ für die erwartete Anzahl der Nicht-Treffer. Es ergibt sich folgende Teststatistik:

$$UK = \sum_{i=1}^2 \frac{(N_i - \hat{N}_i)^2}{\hat{N}_i}. \quad (2.33)$$

Die Teststatistik UK ist unter der Nullhypothese der unbedingten korrekten Überdeckung asymptotisch χ^2 -verteilt mit einem Freiheitsgrad.

- **Test auf Unabhängigkeit:** Der zuvor dargestellte Test berücksichtigt keine mögliche zeitliche Struktur der Intervalle bzw. der Volatilität der Fehler. Der Aspekt der Heteroskedastie wird vernachlässigt. Liegen die Treffer eines homoskedastischen Prognosemodells zeitlich beieinander und ebenso die Nicht-Treffer, wäre dies ein Indiz für eine zeitvariierende Prognoseunsicherheit. Der Test auf Unabhängigkeit dient dazu, zu überprüfen, ob dieses

⁴⁷Die nominellen Prognoseintervalle werden im Fall der nicht-linearen Modelle für jeden Prognosezeitpunkt per Simulation gewonnen. Der aus dem Stützzeitraum geschätzte Prozess wird 10.000 Mal unter Berücksichtigung der Störgröße fortgeschrieben. Aus diesen 10.000 Simulationen werden die notwendigen Quantile abgelesen. Im Fall vom 80 % Intervall wird das 10 % und das 90 % Quantil abgelesen.

Phänomen eine Rolle spielt bzw. ob heteroskedastische Prognosemodelle diesem Rechnung tragen können. Dazu werden die Prognoseintervalle nicht in zwei Kategorien (Treffer und Nicht-Treffer), sondern in vier Kategorien unterteilt, wobei N_{11} die Anzahl der Treffer, denen ein Treffer vorausging, N_{12} die Anzahl der Treffer, denen ein Nicht-Treffer vorausging, N_{21} die Anzahl der Nicht-Treffer, denen ein Treffer vorausging und N_{22} die Anzahl der Nicht-Treffer, denen ein Nicht-Treffer vorausging, ist. Bei Unabhängigkeit kann die erwartete Anzahl \widehat{N}_{ij} aus der Überdeckungswahrscheinlichkeit hergeleitet werden:

$$\widehat{N}_{ij} = N p_N^{-(i-2)} p_N^{-(j-2)} (1 - p_N)^{i-1} (1 - p_N)^{j-1}, \quad i, j \in \{1; 2\}.$$

Setzt man an die Stelle von p_N den Schätzer N_1/N ein, ergibt sich folgende Teststatistik:

$$UN = \sum_{i=1}^2 \sum_{j=1}^2 \frac{\left(N_{ij} - \frac{N_i N_j}{N}\right)^2}{\frac{N_i N_j}{N}}. \quad (2.34)$$

Asymptotisch folgt die Teststatistik einer χ^2 -Verteilung mit einem Freiheitsgrad. Die Nullhypothese der Unabhängigkeit kann als eine Restriktion der Parameter einer Markov-Kette aufgefasst werden ($p_{11} = p_{12}$, was gleichzeitig $p_{22} = p_{21}$ impliziert).⁴⁸

- **Test auf bedingte korrekte Überdeckung:** Beide Aspekte können in einem Test gemeinsam getestet werden. Die entsprechende Teststatistik lautet:

$$BK = \sum_{i=1}^2 \sum_{j=1}^2 \frac{(N_{ij} - \pi_i N_j)^2}{\pi_i N_j}, \quad (2.35)$$

wobei π_1 die nominelle Überdeckungswahrscheinlichkeit p_N sei und π_2 das entsprechende Komplement. Die Teststatistik folgt asymptotisch einer χ^2 -Verteilung mit zwei Freiheitsgraden.

Ein weiteres und umfassenderes Mittel die Unsicherheit von Prognosen und des Prognoseprozess abzubilden sind Dichteprognosen und deren Evaluierung.⁴⁹ Während Intervallprognosen nur bestimmte Konfidenzintervalle spezifizieren berücksichtigen Dichteprognosen die gesamte Verteilung. Dabei werden die Werte der Verteilungsfunktion der Prognosen für die Realisationen der prognostizierten Variable ermittelt. Unter der Nullhypothese, dass die Prognoseverteilung des zu überprüfenden Prognosemodells die wahre Prognoseverteilung darstellt, entstammen die Werte der Verteilungsfunktion einer (0,1)-Gleichverteilung. Dies kann z.B. mit Hilfe eines Komolgoroff-Smirnoff-Test überprüft werden. Wegen der geringen Anzahl an Beobachtungen wird an dieser Stelle auf die Evaluation der Dichteprognosen der verschiedenen BIP-Wachstumsmodelle verzichtet.

⁴⁸Vgl. Christoffersen (1998).

⁴⁹Vgl. Diebold et al. (1998).

Tabelle 2.5: Relative MSE der Prognosen

	1-Schritt	2-Schritt	4-Schritt
AR	0,883	0,906	0,948
MSI	0,857	0,887	0,962
MSIH	0,909	0,952	0,981
MSA	0,811	0,870	0,953
MSAH	0,788	0,873	0,918
BB	1,558	1,006	1,015
SETAR	0,808	0,834	0,961
FC	1,044	1,164	1,338
DLR	1,256	1,035	1,067

2.6.4 Prognoseergebnisse

Punktprognosen

Tabelle 2.5 gibt den mittleren quadratischen Prognosefehler (MSE) der Modelle an. Die Werte sind relativ zum MSE des Mittelwertes des jeweiligen Stützzeitraums. Das AR-Modell, die Markov-Switching-Modelle und das SETAR-Modell weisen in allen Prognosehorizonten bessere Werte als die naive Prognose durch den Mittelwert auf. Das Bounce-Back-Modell, das Floor-Ceiling-Modell, sowie das DLR-Modell weisen schlechtere Werte auf. Bezogen auf die Ein- und Zwei-Schritt-Prognosen weisen das SETAR-Modell sowie die Markov-Switching-Modelle mit Ausnahme des MSIH-Modells bessere Werte als das AR-Modell auf. Die besten Ergebnisse liefern das MSA- bzw. das MSAH-Modell. Bezogen auf die Vier-Schritt-Prognosefehler ist nur das MSAH-Modell besser als das AR-Modell.

In Tabelle 2.6 werden die Werte der Diebold-Mariano Teststatistik (DM) angegeben. Sie wird dazu verwendet, die Signifikanz der MSE-Differenzen zu überprüfen. Unter der Nullhypothese, dass beide Modelle gleich gute Vorhersagen machen, folgt DM asymptotisch einer Standardnormalverteilung, sofern die Modelle nicht genistet sind. An dieser Stelle wird die von Harvey et al. (1997) für kleine Stichproben vorgeschlagene Korrektur der Teststatistik verwendet, so dass diese mit den kritischen Werten einer t -Verteilung verglichen werden. Die Werte sind wie folgt zu interpretieren: ein negativer Wert bedeutet, dass der Prognosefehler des Modells in der Zeile niedriger ist als der des Modells in der Spalte. Handelt es sich um eine Teststatistik mit einem genisteten Modellpaar, ist der Wert in Tabelle 2.6 kursiv gedruckt und es werden keine Signifikanzniveaus angegeben.⁵⁰ Da in der vorliegenden Reihenfolge der Modelle restringierte vor

⁵⁰McCracken (1999) gibt die kritischen Werten der asymptotischen Verteilung der DM -Statistik für den Fall von Ein-Schritt-Prognosen an. Diese beziehen sich aber nur auf die Verteilungen im Vergleich linearer genistete Modelle und sind nur für diesen Prognosehorizont verfügbar. Sie werden daher an dieser Stelle nicht verwendet.

unrestringierten Modellen aufgeführt werden, können kursive negative Werte der *DM*-Statistik als Evidenz für das restringierte Modell gewertet werden. Bei positiven Werten ist wiederum zu beachten, dass die korrespondierenden kritischen Werte kleiner sind, als die für nicht-genistete Modelle.⁵¹

Die Ein-Schritt-Prognosen des Bounce-Back-Modells, des Floor-Ceiling-Modells und des DLR-Modells sind zum 5 % Niveau schlechter als die Ein-Schritt-Prognosen des SETAR-Modells sowie der MSA- und MSAH-Modelle. Das MSI-Modell ist im Bounce-Back-Modell genistet. Der negative Wert der Teststatistik spricht für das MSI-Modell. Ferner sind die Prognosen des MSI-Modell zum 5 % Niveau besser als die des Floor-Ceiling-Modells und des DLR-Modells. Die Prognosen des MSIH-Modells sind zum 10 % Niveau besser als die des Bounce-Back-Modells und zum 5 % Niveau als die des DLR-Modells. Ferner sind die Ein-Schritt-Prognosen des AR-Modells zum 5 % Niveau besser als die des DLR-Modells. Bezogen auf die Zwei-Schritt-Prognosen lassen sich signifikante Aussagen nur für das Floor-Ceiling-Modell machen. Dessen Prognosen sind mindestens zum 5 % Niveau schlechter als die des MSA-, MSAH-, MSI- und SETAR-Modells. Gleiches gilt zum 10 % Niveau für die Vier-Schritt-Prognosen, wobei zusätzlich die Prognose des DLR-Modells die des Floor-Ceiling-Modells dominieren.

Neben dem Diebold-Mariano-Test auf gleiche Vorhersagegüte hat sich der Encompassing-Test von Harvey et al. (1998) etabliert. Beim Vergleich zweier Modelle i und j können zwei Hypothesen aufgestellt werden: Erstens, dass die Prognosen von i die von j "umfassen" und zweitens, dass die Prognosen von j die von i "umfassen". Ist i das bessere Modell sollte der Test die erste Hypothese annehmen und die zweite verwerfen. Der Encompassing-Test ist einseitig. Analog zum Diebold-Mariano-Test bietet sich eine Korrektur für kleine Stichproben an. Tabelle 2.7 gibt die Werte der Teststatistiken *ENC* sowie die Signifikanzniveaus an. Die Einträge sind wie folgt organisiert: Die Modelle in den Zeilen entsprechen dem Modell i und die in den Spalten dem Modell j . In der Darstellung fehlen die Werte des Bounce-Back-Modells, da eine Voraussetzung des Encompassing-Tests von den Prognosen des Modells nicht erfüllt ist. Damit die asymptotische Normal- bzw. t -Verteilung angenommen werden kann, müssen die Fehler im Mittel null sein bzw. die beiden Modelle Fehler mit einem identischen Mittelwert haben. Die Fehler des Bounce-Back-Modells sind jedoch im Mittel für alle betrachteten Prognosehorizonte signifikant positiv.

Die Prognosen des MSA- sowie des MSAH-Modell umfassen die Prognosen aller anderen Modelle in allen drei betrachteten Prognosehorizonten. Für das SETAR-Modell gilt dies immerhin für die Zwei-Schritt und Vier-Schritt-Prognosen. Die Ein-Schritt-Prognosen können die Prognosen des MSAH-Modells zum 5 % Niveau nicht umfassen. Für die Prognosen des Floor-Ceiling- sowie des DLR-Modells wird die Hypothese, dass sie andere Prognosen umfassen, in allen Fällen mindestens zum 5 % Niveau abgelehnt. Das MSA- sowie das MSAH-Modell sind entsprechend

⁵¹Vgl. McCracken (1999) sowie Clark und McCracken (2001).

der Encompassing-Tests sowie bei den Ein-Schritt-Prognosen auch entsprechend der Diebold-Mariano-Tests die besten Prognosemodelle. Bei den Zwei-Schritt-Prognosen ist zusätzlich das SETAR-Modell zu nennen, das dort den kleinsten MSE aufweist und dessen Prognosen für diesen Horizont alle anderen Prognosen umfasst.

Im bisherigen Vergleich der Encompassing-Tests wurde das AR-Modell nur dem DLR-Modell gegenüber gestellt, da diese nicht ineinander genistet sind. Für den Vergleich des AR-Modells mit den anderen Modellen, in denen es genistet ist, wird die Teststatistik von Clark und West (2007) herangezogen, die zwar der von Harvey et al. (1998) entspricht, für die Clark und West jedoch als Approximation die Verwendung der Standardnormalverteilung (insbesondere in kleinen Stichproben) empfehlen. Diese Approximation wird an dieser Stelle durchgängig verwendet, um lineare wie nicht-lineare genistete Modelle miteinander zu vergleichen, siehe Tabelle 2.8. Im Unterschied zum Encompassing-Test von Harvey et al. (1998) kann die Hypothese nicht umgekehrt werden. Es bietet sich ausschließlich an zu testen, ob die Prognosen des genisteten Modells die des unrestringierten Modells umfassen. Bei einem Prognosehorizont von einem Quartal sind die Prognosen des MSA-Modells zum 5 % Niveau und die des MSAH-Modells zum 1 % Niveau besser als die des AR-Modells. Die Prognosen des SETAR-Modells sind noch zum 10 % Niveau signifikant. Bezogen auf die Zwei-Schritt-Prognosen sind nur die Prognosen des SETAR-Modells signifikant besser als die des einfacheren AR-Modells. Schließlich zeigt sich bei den Vier-Schritt-Prognosen, dass die Prognosen des MSAH-Modells signifikant besser sind als die des AR-Modells (10 % Niveau) sowie besser als die des MSA-Modells (1 % Niveau), das ebenfalls im MSAH-Modell genistet ist.

Intervallprognosen

Für alle Modelle werden die Teststatistiken für den Test auf unbedingte korrekte Überdeckung berechnet. Die Tests auf Unabhängigkeit und bedingte korrekte Überdeckung werden nur ausgeführt, wenn die Hypothese der unbedingten korrekten Überdeckung zum 5 % Niveau nicht verworfen werden kann. In Tabelle 2.9 sind die p -Werte der Tests auf unbedingte korrekte Überdeckung abgetragen, die aus der χ^2 -Verteilung entstammen. Das Testintervall ist das zentrale 80 % Intervall. Ein größeres (vielleicht üblicheres) Intervall wurde nicht gewählt, um eine hinreichende Klassenbesetzung zu garantieren. Für das MSIH-, Bounce-Back-, Floor-Ceiling- und DLR-Modell kann der Test die Nullhypothese der unbedingten korrekten Überdeckung bei den Ein-Schritt-Prognosefehlern nicht ablehnen. Das Gleiche gilt auch für die Zwei-Schritt-Prognosefehler. Bei den Vier-Schritt-Prognosefehlern wird die Hypothese beim MSAH-, dem MSIH- und dem Bounce-Back-Modell nicht verworfen.

Für diese Modelle werden die beiden anderen diskutierten Tests durchgeführt. Da die Klassenbesetzung zum Teil sehr gering und somit die Approximation durch die χ^2 -Verteilung problematisch ist, werden die p -Werte für diese Tests per Simulation gewonnen. Jeweils werden

Tabelle 2.6: Test auf gleiche Prognosegüte (Diebold und Mariano [1995])

Ein-Schritt-Prognosen								
	MSA	MSAH	MSI	MSIH	BB	SETAR	FC	DLR
AR	<i>1,446</i>	<i>1,902</i>	<i>0,672</i>	<i>-0,388</i>	<i>-1,839</i>	<i>1,518</i>	<i>-1,741</i>	-2,104
MSA	–	<i>0,740</i>	-0,757	-1,234	-2,107**	0,049	-2,009**	-2,303**
MSAH	–	–	-1,110	-1,601	-2,211**	-0,281	-2,029**	-2,440**
MSI	–	–	–	<i>-1,151</i>	<i>-1,839</i>	0,736	-2,098**	-2,519**
MSIH	–	–	–	–	-1,712*	1,243	-1,207	-2,266**
BB	–	–	–	–	–	2,019**	1,157	0,690
SETAR	–	–	–	–	–	–	-2,458**	-2,234**
FC	–	–	–	–	–	–	–	-1,090

Zwei-Schritt-Prognosen								
	MSA	MSAH	MSI	MSIH	BB	SETAR	FC	DLR
AR	<i>0,820</i>	<i>0,753</i>	<i>0,870</i>	<i>-0,728</i>	<i>-0,431</i>	<i>1,354</i>	<i>-2,326</i>	-0,777
MSA	–	<i>-0,099</i>	-0,353	-1,109	-0,593	0,633	-2,301**	-0,942
MSAH	–	–	-0,317	-1,264	-0,641	0,752	-2,134**	-0,938
MSI	–	–	–	<i>-1,178</i>	<i>-0,494</i>	0,910	-2,623**	-0,876
MSIH	–	–	–	–	-0,242	1,521	-1,510	-0,546
BB	–	–	–	–	–	0,713	-0,435	-0,109
SETAR	–	–	–	–	–	–	-2,741***	1,041
FC	–	–	–	–	–	–	–	0,517

Vier-Schritt-Prognosen								
	MSA	MSAH	MSI	MSIH	BB	SETAR	FC	DLR
AR	<i>-0,112</i>	<i>1,046</i>	<i>-0,957</i>	<i>-0,375</i>	<i>-0,214</i>	<i>-0,419</i>	<i>-2,084</i>	-0,896
MSA	–	<i>0,700</i>	-0,223	-0,298	-0,205	-0,152	-1,913*	-0,949
MSAH	–	–	-1,014	-0,744	-0,351	-0,724	-1,811*	-0,976
MSI	–	–	–	<i>-0,225</i>	<i>-0,168</i>	0,032	-1,980*	-0,771
MSIH	–	–	–	–	-0,110	0,232	-1,560	-0,635
BB	–	–	–	–	–	0,166	-0,704	-0,133
SETAR	–	–	–	–	–	–	-2,068**	-0,898
FC	–	–	–	–	–	–	–	1,982*

Die Tabelle zeigt die Werte der Teststatistik. Es gelten die folgenden Signifikanzen: * signifikant zum 10 % Niveau; ** signifikant zum 5 % Niveau; *** signifikant zum 1 % Niveau. Die kursiven Werte beziehen sich auf genistete Modelle. Der Test ist dann einseitig. In diesem Fall werden keine Signifikanzniveaus angegeben.

Tabelle 2.7: Encompassing-Test (Harvey et al. [1998])

Ein-Schritt-Prognosen								
	AR	MSA	MSAH	MSI	MSIH	SETAR	FC	DLR
AR	–							0,022
MSA		–		-0,207	0,103	0,775	-0,945	-0,069
MSAH			–	-0,800	-0,372	0,346	-1,151	-0,076
MSI		1,260	1,670**	–		0,991	-0,923	-0,645
MSIH		2,413**	2,735***		–	1,824**	0,809	-0,799
SETAR		1,266	1,888**	0,893	0,659	–	-1,123	0,304
FC		2,936***	3,192***	3,119***	3,126***	2,835***	–	1,198
DLR	3,648***	3,924***	4,013***	3,738***	3,235***	2,924***	3,113***	–

Zwei-Schritt-Prognosen								
	AR	MSA	MSAH	MSI	MSIH	SETAR	FC	DLR
AR	–							0,633
MSA		–		0,047	0,144	1,012	-1,323	0,526
MSAH			–	-0,131	0,036	0,962	-1,285	0,544
MSI		0,751	0,612	–		1,002	-1,548	0,485
MSIH		2,061**	2,016**		–	1,878**	0,290	0,634
SETAR		0,405	0,053	0,622	0,469	–	-1,377	0,823
FC		3,171***	3,347***	3,632***	3,361***	3,151***	–	1,490*
DLR	2,164**	2,386**	2,299**	2,220**	1,665*	1,904**	1,047	–

Vier-Schritt-Prognosen								
	AR	MSA	MSAH	MSI	MSIH	SETAR	FC	DLR
AR	–							0,265
MSA		–		-0,034	0,506	-0,017	-1,203	0,227
MSAH			–	-1,105	-0,001	-0,838	-1,238	0,140
MSI		0,405	1,259	–		0,177	-1,273	0,361
MSIH		0,881	1,179		–	0,759	-0,211	0,467
SETAR		0,281	0,882	0,107	0,567	–	-1,347	0,338
FC		2,533***	2,595***	2,566***	2,331	2,612***	–	2,767***
DLR	1,906**	2,056**	2,000**	1,835**	1,599*	1,955**	0,062	–

Die Tabelle zeigt die Werte der Teststatistik. Es gelten die folgenden Signifikanzen: * signifikant zum 10 % Niveau; ** signifikant zum 5 % Niveau; *** signifikant zum 1 % Niveau. Sofern die Modelle genistet sind, wird keine Teststatistik berichtet. Für den Vergleich genisteter Modelle siehe Tabelle 2.8.

Tabelle 2.8: Test auf gleiche Prognosegüte genisteter Modelle (Clark und West [2007])

Ein-Schritt-Prognosen							
	AR	MSA	MSAH	MSI	MSIH	SETAR	FC
AR	–	1,957**	2,618***	1,100	0,999	1,363*	-0,868
MSA	–	–	1,171	–	–	–	–
MSI	–	–	–	–	-0,071	–	–

Zwei-Schritt-Prognosen							
	AR	MSA	MSAH	MSI	MSIH	SETAR	FC
AR	–	1,082	0,997	1,115	0,625	1,284*	-1,385
MSA	–	–	0,258	–	–	–	–
MSI	–	–	–	–	-0,145	–	–

Vier-Schritt-Prognosen							
	AR	MSA	MSAH	MSI	MSIH	SETAR	FC
AR	–	0,019	1,360*	-0,809	0,393	-0,267	-1,374
MSA	–	–	2,229**	–	–	–	–
MSI	–	–	–	–	0,488	–	–

Die Tabelle zeigt die Werte der Teststatistik. Es gelten die folgenden Signifikanzen: * signifikant zum 10 % Niveau; ** signifikant zum 5 % Niveau; *** signifikant zum 1 % Niveau.

Tabelle 2.9: Test auf unbedingte korrekte Überdeckung

	1-Schritt	2-Schritt	4-Schritt
AR	0,002	0,007	0,003
MSA	0,007	0,007	0,010
MSAH	0,007	0,023	0,080
MSI	0,020	0,023	0,030
MSIH	0,128	0,144	0,080
BB	0,938	0,062	0,080
SETAR	0,007	0,007	0,010
FC	0,262	0,062	0,030
DLR	0,262	0,062	0,010

p-Werte der simulierten Verteilung

Tabelle 2.10: Test auf zeitliche Unabhängigkeit der Überdeckung

	1-Schritt	2-Schritt	4-Schritt
MSAH	–	–	0,159
MSIH	0,844	0,850	0,855
BB	0,126	0,021	0,024
FC	0,015	0,157	–
DLR	0,489	0,865	–

p-Werte der simulierten Verteilung

Tabelle 2.11: Test auf bedingte korrekte Überdeckung

	1-Schritt	2-Schritt	4-Schritt
MSAH	–	–	0,302
MSIH	0,372	0,369	0,232
BB	0,203	0,087	0,101
FC	0,015	0,293	–
DLR	0,187	0,025	–

p-Werte der simulierten Verteilung

wiederholt (10.000 Mal) Zahlenfolgen bzw. ein Vektor einer binären Variablen ermittelt, deren Länge dem Umfang des Prognosezeitraums entspricht. Die binären Variablen werden unabhängig voneinander aus einer Bernoulli-Verteilung mit der nominellen Überdeckungswahrscheinlichkeit als Parameter simuliert. Der Wert eins der binären Variable kann als Treffer in Hinsicht auf das Prognoseintervall gesehen werden. Auf Grundlage der simulierten Daten werden die beiden Teststatistiken berechnet und somit deren Verteilungen simuliert. In Tabelle 2.10 sind die *p*-Werte des Tests auf Unabhängigkeit angegeben. Die Hypothese der Unabhängigkeit wird in den meisten Fällen zum gängigen Fehlerniveau von 5 % nicht verworfen. Ausnahmen sind das Floor-Ceiling-Modell bei den Ein-Schritt-Prognosen sowie das Bounce-Back-Modell bei den Zwei- und Vier-Schritt-Prognosen.

Tabelle 2.11 zeigt die ebenfalls per Simulation gewonnen *p*-Werte des Tests auf bedingte korrekte Überdeckung. Hier wird die Nullhypothese zum 5 % Niveau wiederum beim Floor-Ceiling-Modell im Fall der Ein-Schritt-Prognosen und beim DLR-Modell im Fall der Zwei-Schritt-Prognosen verworfen.

Zusammenfassung

Die MSA- und MSAH-Modelle sowie das SETAR-Modell, die alle variierende autoregressive Koeffizienten aufweisen, schneiden bei den Punktprognosen insbesondere bei den Ein-Schritt-Prognosen am besten ab, wobei sie bei den Zwei-Schritt- und Vier-Schritt-Prognosen kaum eine Verbesserung zum AR-Modell bewirken. Auffallend ist, dass die Modelle mit guten Punktprognosen zum Teil schlechte Intervallprognosen ergeben. Das Floor-Ceiling-, das DLR- und das Bounce-Back-Modell, die durchweg die schlechtesten Punktprognosen liefern, schneiden bei den Intervallprognosen mit am besten ab. Zu erwähnen ist hier insbesondere das MSIH-Modell, dessen gutes Abschneiden bei den Intervallprognosen nochmals auf einen Bruch in der Volatilität des deutschen BIP-Wachstums hinweist.⁵²

Die Prognoseergebnisse, insbesondere die Ergebnisse für die Punktprognosen stehen zum Teil in erheblichem Widerspruch zu den Ergebnisse der Untersuchung der In-Sample-Modellgüte. Dies ist wiederum ein Hinweis für strukturelle Veränderungen im deutschen BIP, die auch durch die Verwendung nicht-linearer Spezifikationen nicht aufgefangen werden können.

⁵²Vgl. Kapitel 4.

Kapitel 3

Reproduktion der Konjunkturzykluseigenschaften

3.1 Konjunkturzykluseigenschaften als Stilisierte Fakten

Die Wahrnehmung des Konjunkturverlaufs als Abfolge von Expansionen und Kontraktionen ist weit verbreitet. Burns und Mitchell (1946) haben in ihrer Arbeit zwar diese Konjunkturphasen noch weiter unterschieden; die zuvor genannte Unterscheidung in Expansionen und Kontraktionen bzw. Rezessionen wird aber zum Beispiel vom NBER verfolgt und die vom NBER veröffentlichten Wechsellpunkte, die die Rezessionen markieren, werden allgemein als der Konjunkturzyklus der USA anerkannt.

Die Beobachtung des Konjunkturzyklus und seiner Datierung birgt in sich eine alternative Methode zur Beurteilung von Modellen des BIP-Wachstums. Die in Kapitel 2 besprochenen Ansätze basieren auf der Likelihood oder den Residuen des Modells. Es kann jedoch durch die Minimierung der quadrierten Residuen nicht garantiert werden, dass Modelle, die anhand dieser Kriterien gut abschneiden, auch den tatsächlich beobachteten Konjunkturzyklus reproduzieren können, bzw. das BIP-Wachstum reproduzieren können, welches mit dem beobachteten Konjunkturzyklus korrespondiert.

Hess und Iwata (1997) stellen die Frage, ob die für das BIP-Wachstum entwickelten nicht-linearen Modelle gut bzw. besser als lineare Modelle geeignet sind, den Konjunkturzyklus der USA nachzubilden. Erster Schritt bei dieser Methode der Modellevaluation ist die Feststellung der Eigenschaften des tatsächlichen Konjunkturzyklus, wie Anzahl von Zyklen, Dauer und Tiefe von Rezessionen und Expansionen. Diese Daten gelten als stilisierte Fakten. In Abbildung 3.1 werden die Konjunkturzykluseigenschaften schematisch illustriert. Die Tiefe der Rezession und die Höhe der Expansion wird im Folgenden als mittlere Wachstumsrate dieser Konjunkturphasen gemessen. Durch die Festlegung der Wechsellpunkte werden die Anzahl der Rezessionen und

Expansionen sowie deren Dauer bestimmt.

Für die Datierung der Wechsellpunkte der Konjunktur muss ein reproduzierbares Verfahren verwendet werden,¹ da das gleiche Datierungsverfahren in der Folge wiederholt angewendet werden muss. Die Modelle, deren Eigenschaften überprüft werden sollen, werden zur Simulation von mehreren tausend Zeitreihen herangezogen und für jede einzelne der Zyklus sowie dessen Eigenschaften ermittelt. Aus der Vielzahl der Simulationen wird die empirische Verteilung der Eigenschaften ermittelt und mit den stilisierten Fakten verglichen.

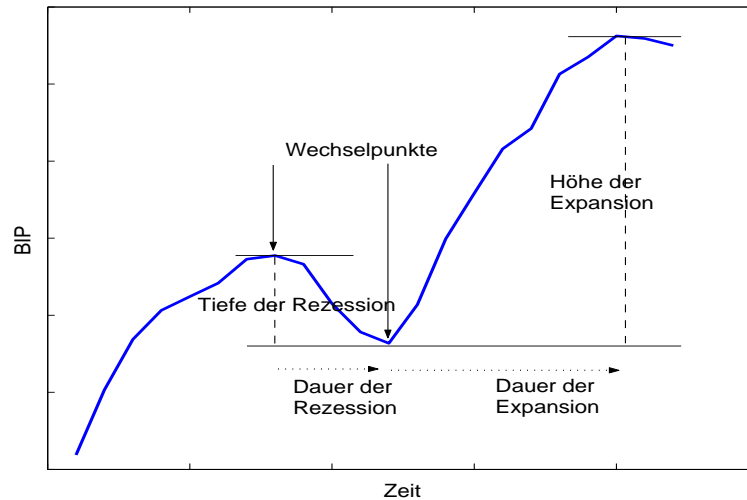
Modelle der Frage zu unterziehen, ob sie der Realität ähnliche Konjunkturzyklen erzeugen können, geht auf die Arbeit von Adelman und Adelman (1959) zurück, die damit ökonomische Modelle überprüfen, und wird z.B. von King und Plosser (1994) sowie Simkins (1994) auf Real-Business-Cycle-Modelle angewendet. Ausgehend von Hess und Iwata (1997), die eine Vielzahl von Zeitreihenmodellen untersuchen, jedoch eine ad-hoc Definition des Konjunkturzyklus verwenden, sind mehrere Arbeiten zur Reproduzierbarkeit des Konjunkturzyklus durch nicht-linearen Modelle für das US BIP-Wachstum entstanden. Harding und Pagan (2002) verwenden eine modifizierte Form des Algorithmus von Bry und Boschan (1971), die auf Quartalsdaten abgestimmt ist und auf Watson (1994) zurückgeht. Mit dieser verbesserten Methode zur Bestimmung der konjunkturellen Wechsellpunkte analysieren sie das Hamilton-Modell (MSM mit zwei Zuständen) sowie dessen Erweiterung von Durland and McCurdy (1994) im Vergleich zu linearen Modellen. Basierend auf dem modifizierten Bry-Boschan-Algorithmus arbeiten Morley und Piger (2004) und Kim et al. (2005) mit dem MSM-Modell mit zwei sowie drei Zuständen, dem Bounce-Back-Modell sowie mehreren linearen Modellen. Engel et al. (2005) berücksichtigen das Floor-Ceiling-Modell sowie das Bounce-Back-Modell.² Während Hess und Iwata (1997), Harding und Pagan (2002) sowie Engel et al. (2005) keinen Vorzug für nicht-lineare Modelle angesichts der von diesen Autoren betrachteten Konjunkturzykluseigenschaften finden, zeigen Morley und Piger (2004) sowie Kim et al. (2005), dass unter Berücksichtigung der zusätzlichen Eigenschaft der Korrelation zwischen der Tiefe der Rezession und dem Wachstum nach der Rezession das von Kim et al. (2005) vorgeschlagene Bounce-Back Modell sowie ein Markov-Switching-Modell mit drei Zuständen diese Eigenschaft der US Daten besser nachbilden können.

In diesem Kapitel wird der Ansatz von Hess und Iwata (1997) aufgegriffen, Modelle über ihre Eignung Konjunkturzykluseigenschaften zu reproduzieren zu analysieren, und wendet ihn auf das deutsche BIP und die in Kapitel 2 dargestellten Modelle an. Neben den Konjunkturzykluseigenschaften, Häufigkeit, Länge und Tiefe von Konjunkturphasen, werden zusätzlich weitere Eigenschaften in dieser Simulationsstudie berücksichtigt, die explizit im Zusammenhang mit nicht-linearen Modellen diskutiert werden. Zur Motivation nicht-linearer Modelle des

¹Die NBER-Daten oder ähnliche Daten anderer Institutionen können also nicht zur Anwendung kommen, vielmehr ist es von Bedeutung ein reproduzierbares Verfahren zu verwenden, dessen Ergebnisse dem NBER-Zyklus möglichst gut entsprechen.

²In einem Arbeitspapier wird außerdem das DLR-Modell berücksichtigt.

Abbildung 3.1: Eigenschaften des Konjunkturzyklus



BIP-Wachstums wird wie bereits erwähnt mit möglichen Asymmetrien des Konjunkturverlaufs argumentiert. Im folgenden Abschnitt werden die Maßzahlen erläutert, die in erster Linie dazu dienen auf Asymmetrien zu testen und die an dieser Stelle als stilisierte Fakten des Konjunkturvariable benutzt werden. Sie bilden zusätzliche Eigenschaften, die zur Beurteilung der Modelle des BIP-Wachstums neben den bereits erwähnten Konjunkturzykluseigenschaften herangezogen werden.

Das Vorgehen, Werte von Teststatistiken bzw. deren p -Werte als stilisierte Fakten aufzufassen und darauf aufbauend Spezifikationstests zu entwickeln, finden sich auch in Ashley und Patterson (2006), die nicht-parametrische Tests auf Nicht-Linearitäten, wie der BDS-Test (Brock et al. [1996]), auf die zu modellierende Zeitreihe anwenden und die resultierenden p -Werte mit denen von simulierten Zeitreihen nicht-linearer Modelle vergleichen.

3.2 Asymmetrien im deutschen Konjunkturverlauf

3.2.1 Formen der Asymmetrie

In diesem Abschnitt werden verschiedene Formen der Asymmetrie des Konjunkturzyklus bzw. des BIP dargestellt, die in der Literatur insbesondere für die USA diskutiert werden. Zu den Formen der Asymmetrien korrespondieren Maßzahlen und Teststatistiken, die in diesem Abschnitt dargestellt und für das deutsche BIP-Wachstum berechnet werden. Die resultierenden Werte gelten als stilisierte Fakten und fließen in die Simulation zur Frage, ob die verschiedenen Modelle des BIP-Wachstums die tatsächlichen Konjunkturzykluseigenschaften abbilden können, mit ein. Folgende Asymmetrien werden an dieser Stelle berücksichtigt:

- (a) **Tiefe**, die durch die Schiefe der trendbereinigten Niveauvariablen gemessen werden kann.³ Hat die Verteilung des trendbereinigten BIP eine negative Schiefe, heißt das, dass weniger aber dafür ausgeprägtere negative Abweichungen vom Trend existieren. In tiefen Prozessen sind die absoluten Abweichungen vom Trend in der Rezession stärker als in der Expansion.
- (b) **Steilheit**, die durch die Schiefe der ersten Differenzen des BIP gemessen wird. Sie bedeutet, dass Rückgänge des BIP seltener aber dafür stärker als die Zunahmen relativ zum mittleren Wachstum sind.⁴
- (c) **Schärfe**, bedeutet, dass mit dem Ende einer Rezession ein starkes und plötzliches Wachstum auftritt, der Übergang von der Expansion zur Rezession aber eher fließend ist. Die Übergänge von Expansion zu Rezession und umgekehrt sind also asymmetrisch.⁵
- (d) **Dauerabhängigkeit der Konjunkturphasen**, die den Umstand bezeichnet, dass die erwartete Dauer einer Konjunkturphase von der bisherigen Dauer einer solchen abhängt. Wenn die Dauerabhängigkeit der Rezessionen anders als die der Expansionen ist, handelt es sich ebenfalls um eine Form der Asymmetrie des Konjunkturzyklus.⁶

Wie bereits erwähnt, werden diese vier Punkte im Zusammenhang mit der Modellierung des BIP-Wachstums diskutiert, da sie Evidenz gegen lineare Modelle implizieren und somit Hinweise für die Gültigkeit anderer Modelle mit sich bringen. Clements und Krolzig (2003) zeigen welche Parameterkonstellationen in MSM-Modellen Asymmetrien der Formen (a) bis (c) erzeugen. Knüppel (2005) erweitert diesen Ansatz auf MSI-Modelle und zeigt ferner, wie im Rahmen von dynamischen stochastischen allgemeinen Gleichgewichtsmodellen Zeitreihen generiert werden können, die tief und steil sind.

3.2.2 Tests auf Asymmetrie

Tests auf Asymmetrien können verschiedene Modelle als datenerzeugende Prozesse ausschließen. Zu den vier genannten Formen der Asymmetrie existieren verschiedene parametrische und nicht-parametrische Tests. Basierend auf der Arbeit von Clements und Krolzig (2003) lassen sich die Tests auf Asymmetrien der Formen (a) bis (c) als Parameter-tests im MSM-Modell auffassen.⁷ Ferner kann die Asymmetrie (d) über die Modellierung von zeitabhängigen Übergangswahrscheinlichkeiten ebenfalls im Rahmen von Markov-Switching-Modellen formuliert werden, siehe

³Verschiedene Formen des Trends sind denkbar. Hier wird durchgehend der Hodrick-Prescott-Filter zur Trendbereinigung verwendet.

⁴Siehe Sichel (1993) für die Diskussion der Punkte (a) und (b).

⁵Siehe McQueen und Thorley (1993).

⁶Siehe Diebold und Rudebusch (1990).

⁷Für die Schärfe haben bereits McQueen und Thorley (1993) einen Test beruhend auf der Maximum Likelihood Schätzung eines Markov-Switching-Modells vorgeschlagen.

Durland und McCurdy (1994). Im Rahmen eines Simulationsexperiments, in dem verschiedene datenerzeugende Prozesse berücksichtigt werden, bietet sich wegen des Problems lokaler Maxima eine Formulierung der stilisierten Fakten und der zu reproduzierenden Eigenschaften in Form von ML-Schätzungen von Markov-Switching-Modellen nicht an. Die folgenden Tests sind daher entweder nicht-parametrisch bzw. fußen auf einfachen Stichprobenstatistiken.

Sichel (1993) formuliert einen Test auf Tiefe eines Prozesses darüber, dass ein nicht-tiefer Prozess eine Schiefe von Null bzw. größer Null aufweist. Den Test auf eine Schiefe von Null wendet Sichel (1993) auf das trendbereinigte BIP an, wobei verschiedene mögliche Trendbereinigungsverfahren diskutiert werden unter anderem der Hodrick-Prescott-Filter. Die Trendbereinigung ist notwendig, da es bei der Tiefe um die Abweichungen vom Trend und nicht um diesen selber geht. Für die Steilheit eines Prozesses wird die Schiefe der differenzierten Zeitreihe berücksichtigt. Die Nullhypothese ist wiederum, dass keine Steilheit vorliegt und die Schiefe der differenzierten Zeitreihe null ist. Die von Sichel (1993) verwendete Verteilung der Schiefe berücksichtigt jedoch nicht, dass Mittelwert und Standardabweichung in der Berechnung der Schiefe unbekannt sind. Bai und Ng (2005) geben die korrekten Verteilungen an, die ebenfalls eventuelle Autokorrelation in den Daten berücksichtigen.

Sei $\hat{\vartheta}$ die Schiefe der Stichprobe, dann konvergiert die stabilisierende Transformation unter der Nullhypothese wie folgt gegen eine Standardnormalverteilung:

$$\frac{\sqrt{T}\hat{\vartheta}}{s(\hat{\vartheta})} \xrightarrow{d} N(0, 1), \quad (3.1)$$

wobei $s(\hat{\vartheta}) = \frac{\hat{\alpha}\hat{\Gamma}\hat{\alpha}'}{\hat{\sigma}^6}$ und $\alpha = [1, -3\sigma^2]$ sowie Γ die Spektraldichtematrix von $[(y_t - E(y_t))^3, (y_t - E(y_t))]'$ bei der Frequenz von null ist. Γ kann über das Verfahren von Newey und West (1987) konsistent geschätzt werden.

Für die Schiefe des mit dem Hodrick-Prescott-Filter trendbereinigten BIP ergibt sich für deutsche Daten ein Wert von 0,345. Der t -Wert beträgt 1,798. Angesichts eines positiven Wertes der Schiefe nimmt der Test die Nullhypothese eines nicht-tiefen Prozesses auf jeden Fall an. Für die Wachstumsraten ergibt sich ein Wert für die Schiefe von -0,01. Der p -Wert des entsprechende Tests mit der Nullhypothese eines nicht-steilen Prozesses ist 0,536 und kann entsprechend zu keinem typischen Niveau abgelehnt werden.

McQueen und Thorley (1993) verwenden als Maß der Schärfe eines Prozesses die mittlere Differenz zwischen den Differenzen des Wachstums an den Wechsellpunkten. Es werden also an den Wechsellpunkten von Expansionen zu Rezessionen von der jeweiligen Wachstumsrate vor dem Wechsellpunkt die Wachstumsrate nach dem bzw. des Wechsellpunkts abgezogen und diese Differenzen für alle Wechsellpunkte dieses Typs gemittelt. Das Gleiche wird für die Wechsellpunkte in der Gegenrichtung gemacht. Unter der Nullhypothese der Nicht-Schärfe sind die beiden erwarteten Mittelwerte identisch und deren erwartete Differenz ist null. Entsprechend kann ein t -Test durchgeführt werden. Die mittlere Differenz zwischen den Wachstumsraten einer Periode

vor einer Rezession und in der ersten Periode einer Rezession beträgt für das deutsche BIP 4,446, wobei die Wechsellpunkte mit Hilfe des Bry-Boschan-Algorithmus festgelegt worden sind. Die mittlere Differenz zwischen den Wachstumsraten eine Periode vor einer Expansion und in der ersten Periode der Expansion beträgt für das deutsche BIP 4,495. Die Differenz der beiden Werte beträgt 0,0482 und bedenkt man die Standardabweichung der Differenzen der einzelnen Konjunkturzyklen von 1,053 gibt es keinen Hinweis, dass Schärfe im deutschen Konjunkturzyklus vorliegt.⁸

Diebold und Rudebusch (1990) überprüfen die Dauerabhängigkeit der Konjunkturphasenlänge ausgehend von der Überlegung, dass unter der Nullhypothese, dass keine Dauerabhängigkeit besteht, die Phasenlängen exponential verteilt sind. Die Annahme der Exponential-Verteilung für Wartezeiten bzw. der Zeit zwischen zwei Ereignissen entspricht der Annahme, dass der Prozess “gedächtnislos” ist, also die bereits vergangene Wartezeit keinen Einfluss auf die Wahrscheinlichkeit des Endes der Wartezeit hat. Diebold und Rudebusch (1990) verwenden drei Tests, die auf Vorliegen einer Exponential-Verteilung als Nullhypothese testen. Es sei z_i die Dauer der Konjunkturphase bzw. Konjunkturzyklus i und N die Anzahl der Konjunkturphasen bzw. Konjunkturzyklen.

1. Shapiro und Wilk (1972) geben die folgende Teststatistik an:

$$W = \frac{(\bar{z} - z_{(1)})^2}{(N-1)s^2}, \quad (3.2)$$

wobei $z_{(1)}$ die erste Ordnungsstatistik darstellt und $s^2 = 1/N \sum_{i=1}^N (z_i - \bar{z})^2$. In Shapiro und Wilk (1972) finden sich die kritischen Werte dieser Teststatistik für Werte von N zwischen 3 und 100.

2. Stephens (1978) schlägt eine Variante des Tests von Shapiro und Wilk (1972) vor, für die eine eventuelle Mindestdauer der Phasen oder Zyklen explizit angenommen wird. Da durch die Verwendung des Bry-Boschan-Algorithmus Mindestlängen der Rezessionen bzw. Expansionen und des Zyklus vorgegeben sind, können diese Werte hier übernommen werden. Die Mindestlänge sei t_0 . Ferner sei $A = \sum_{i=1}^N (z_i - t_0)$ und $B = \sum_{i=1}^N (z_i - t_0)^2$. Die Teststatistik lautet

$$W(t_0) = \frac{A^2}{N[(N+1)B - A^2]}. \quad (3.3)$$

Sie folgt ebenfalls der von Shapiro und Wilk (1972) angegebenen Verteilung mit dem Unterschied, dass nicht die Werte für N , sondern für $N+1$ berücksichtigt werden müssen.

⁸Die Schärfe ist im Zusammenhang mit dem “Bounce-Back-Effekt” zu sehen. Das vorliegende Ergebnis spricht also auch gegen die Verwendung der Modelle von Beaudry und Koop (1993) oder Kim et al. (2005) für deutsche BIP-Daten.

3. Ferner wird die asymptotisch standardnormalverteilte Teststatistik von Brain und Shapiro (1983) verwendet. Sie beruht auf der folgenden Transformation der Phasenlängen:

$$u_i = (N - i + 1)(z(i) - z(i - 1)) \quad i = 2, \dots, N.$$

In einer Regression von u_i auf i , ist der Regressionsparameter unter der Nullhypothese der Exponentialverteilung gleich null. Dies wird von Brain und Shapiro (1983) verwendet um die folgende Teststatistik aufzustellen:

$$BS = \frac{\sum_{i=1}^{N-1} (i - \bar{i})(u_{i+1} - \bar{u})}{\sum_{i=1}^{N-1} u_{i+1} \left(\sum_{i=1}^{N-1} (i - \bar{i})^2 / [N(N - 1)] \right)}. \quad (3.4)$$

Tabelle 3.1 gibt die Werte der Teststatistiken für die Länge der (beendeten) Konjunkturphasen, die über das BIP mit Hilfe des Bry-Boschan-Algorithmus ermittelt worden sind, an. Unterschieden werden Rezessionen, Expansionen und Konjunkturzyklen, die aus einer Expansion und der folgenden Rezession zusammengesetzt sind. Keiner der Werte ist signifikant zum 5% Niveau, so dass eine Dauerabhängigkeit weder der Rezessionen noch der Expansionen noch der Zyklen festzustellen ist.

Tabelle 3.1: Tests auf Dauerabhängigkeit

	W	$W(t_0)$	BS	N
Expansion	0,364	0,195	-0,402	5
Rezession	0,400	0,222	-1,299	6
Zyklus	0,383	0,222	-0,551	5

Für den hier betrachteten Datensatz des deutschen BIP-Wachstums findet sich kein signifikantes Ergebnis, dass gegen die Hypothese der Symmetrie spricht. Die verschiedenen Tests mit den Gegenhypothese Tiefen, Steilheit, Schärfe und Dauerabhängigkeit führen in keinem Fall zu einer Ablehnung der Nullhypothese Symmetrie, womit die Ergebnisse der Arbeiten von Razzak (2001) und Belaire-Franch und Contreras (2003) bestätigt werden, die für deutsche BIP-Daten bei Tests mit den Gegenhypothese Tiefen, Steilheit und Schärfe ebenfalls keine Ablehnung der Symmetrie finden.⁹

3.3 Datierung von Wechsellpunkten der Konjunktur

Für die USA wird vom NBER die Chronologie der Wechsellpunkte der Konjunktur gepflegt. Die Arbeit des NBER im Bezug auf die Konjunkturforschung geht auf die 20er Jahre des letzten

⁹Während Razzak (2001) nicht-parametrische Methoden in Form des hier nicht beschriebenen Triples-Test verwendet, führen Belaire-Franch und Contreras (2003) die in Clements und Krolzig (2003) beschriebenen auf Markov-Switching-Modellen basierenden parametrischen Tests durch.

Jahrhunderts und das Wirken von Wesley Mitchell zurück. Entsprechend kann die Datierung des Konjunkturzyklus als eine Art Fortsetzung von Burns und Mitchell (1946) angesehen werden. Die Wechsellpunkte der Konjunktur werden von einem Komitee festgelegt, das dazu mehrere Variablen beobachtet.¹⁰ Das BIP wird zwar als wesentlichster Konjunkturindikator angesehen, um jedoch eine monatliche Datierung zu gewährleisten werden insbesondere die Privateinkommen und der Beschäftigungsstand berücksichtigt. Zusätzlich spielen Industrieproduktion und Umsätze eine Rolle. Diese vier Variablen werden in monatlicher Frequenz erhoben.

Für die Datierung von Wechsellpunkten in monatlichen Daten haben Bry und Boschan (1971) einen computergestützten Algorithmus entwickelt, der auch Anwendung beim NBER zur Unterstützung des Komitees gefunden hat. Der Algorithmus wird auf die Niveauvariable angewendet und soll die Phasen, in denen die allgemeine Entwicklung rückläufig ist, von den expansiven Phasen unterscheiden. Damit kurzfristige Schwankungen das Ergebnis nicht beeinflussen, werden verschiedene gleitende Durchschnitte gebildet, für die zuerst die Wechsellpunkte bestimmt werden. Ausgehend von den Ergebnissen für die gleitenden Durchschnitte werden dann die Wechsellpunkte der Ausgangszeitreihe festgelegt. Eine übersichtliche Darstellung des Bry-Boschan-Algorithmus findet sich in Lucke und Knüppel (2002).

Der Bry-Boschan-Algorithmus wurde für Monatsdaten entwickelt und muss für eine Anwendung auf das BIP auf die niedrigere Frequenz angepasst werden. Angelehnt an Watson (1994) ergibt sich der folgende Algorithmus:

1. Ausreißerbestimmung und Substitution extremer Beobachtungen
2. Zyklusbestimmung in einem gleitenden Durchschnitt von 2 Quartalen
 - (a) Bestimmung von Werten, die höher (oder niedriger) sind als alle Werte im Umkreis von einem Quartal
 - (b) Erzwingung alternierender Wendepunkte: Höchster von multiplen oberen Wendepunkten; niedrigster von multiplen unteren Wendepunkten
3. Zyklusbestimmung in einem weniger stark geglätteten gleitenden Durchschnitt (sog. Spencer-Kurve)
 - (a) Bestimmung der höchsten (oder niedrigsten) Werte im Umkreis von 2 Quartalen um die Wendepunkte des gleitenden Durchschnitts von 2 Quartalen
 - (b) Erzwingung der Mindestzykluslänge von 5 Quartalen durch Elimination niedrigerer oberer oder höherer unterer Wendepunkte bei Zyklen kürzerer Dauer

¹⁰Die Datierung des Komitees folgt dabei keinen festgelegten Regeln oder einem Algorithmus, sondern gilt vielmehr als Expertenurteil.

4. Bestimmung der Wendepunkte in einem kurzfristigen gleitenden Durchschnitt von 2 Quartalen
 - (a) Bestimmung der höchsten (oder niedrigsten) Werte im Umkreis von 2 Quartalen um die Wendepunkte der Spencer-Kurve
5. Bestimmung der Wendepunkte in der ungeglätteten Zeitreihe
 - (a) Bestimmung der höchsten (oder niedrigsten) Werte im Umkreis von 2 Quartalen um die Wendepunkte des kurzfristigen gleitenden Durchschnitts
 - (b) Elimination von Wendepunkten, die nicht weiter als 2 Quartale vom Anfang oder Ende der Zeitreihe entfernt liegen
 - (c) Elimination von oberen (oder unteren) Wendepunkten an beiden Enden der Zeitreihe, die niedriger (oder höher) sind als noch näher an den Enden platzierte Werte
 - (d) Elimination von Zyklen mit einer Dauer von weniger als 5 Quartale
 - (e) Elimination von Phasen mit einer Dauer von weniger als 2 Quartale
6. Ausgabe der endgültigen Wendepunkte

Der Bry-Boschan-Algorithmus für Quartalsdaten wird wie erwähnt in der Arbeit von Harding und Pagan (2002) verwendet. Außerdem benutzen Inklaar et al. (2004), Engel et al. (2005) und Everts (2006) den Bry-Boschan-Algorithmus für Quartalsdaten.

3.4 Simulationsergebnisse

Basierend auf den ML-Schätzungen der Modelle des BIP-Wachstums werden von diesen 10.000 Mal Zeitreihen mit dem gleichen Umfang wie der Schätzzeitraum bzw. des für die Feststellung der stilisierten Fakten des Konjunkturzyklus verwendeten Zeitraums simuliert. Für jede Simulation werden mit Hilfe des Bry-Boschan-Algorithmus Wechsellpunkte der Konjunktur bestimmt und die folgenden Kennzahlen ermittelt:¹¹

1. Anzahl (#) der Expansionen
2. Durchschnittliche Dauer einer Expansion
3. Standardabweichung der Dauer einer Expansion
4. Durchschnittliche Höhe der Expansion (Höhe gemessen als mittleres Wachstum)

¹¹Vgl. Hess und Iwata (1997). In der Arbeit von Morley und Piger (2004) werden zusätzlich die Standardabweichungen der Wachstumsraten der unterschiedlichen Regime sowie die Standardabweichungen der Dauer aufgenommen.

5. Standardabweichung der Höhe der Expansionen
6. Anzahl (#) der Rezessionen
7. Durchschnittliche Dauer einer Rezession
8. Standardabweichung der Dauer einer Rezession
9. Durchschnittliche Tiefe der Rezession (Tiefe gemessen als mittleres Wachstum)
10. Standardabweichung der Tiefe der Rezessionen

Zusätzlich zum Ansatz von Hess und Iwata (1997) werden für jede Simulation die in Abschnitt 3.2.1 besprochenen Asymmetriemaße errechnet. Die mit dem Begriff "Schärfe" diskutierte Form der Asymmetrie kann analog zu der von Kim et al. (2005) diskutierten Korrelation zwischen Tiefe der Rezession und dem Wachstum nach der Rezession als Eigenschaft des Konjunkturzyklus gesehen werden.

11. Schiefe der (Hodrick-Prescott-)gefilterten Niveauvariable (Tiefe des Prozess)
12. Schiefe der Wachstumsraten bzw. der simulierten Zeitreihe (Steilheit)
13. Schärfe als mittlere Differenz der Wachstumsratendifferenzen an den Wechsellpunkten der Konjunktur

Mit den jeweils 10.000 Werten wird die Verteilungsfunktion der Kennzahlen eines Modells über die empirische Verteilungsfunktion approximiert. In Tabelle 3.2 werden die Mediane der Randverteilungen der einzelnen Kennzahlen, sowie der Wert der Randverteilungen an der Stelle der tatsächlich realisierten Kennzahl des deutschen BIP dargestellt. Für die Kennzahl der "Schärfe" werden nur die Simulationen herangezogen, die mehr als einen abgeschlossenen Konjunkturzyklus aufweisen. Für alle anderen Kennzahlen sind 10.000 Simulationen die Grundlage. Sofern sich die Kennzahlen nicht auf die Wachstumsraten beziehen, sondern auf die Niveauvariable bzw. für die Anwendung des Bry-Boschan-Algorithmus wird die Niveauvariable aus den simulierten Wachstumsraten errechnet. Insbesondere die Werte der Verteilungsfunktionen geben Aufschluss, ob der tatsächliche Konjunkturverlauf aus der Mitte der Verteilung stammt oder aus Sicht des jeweiligen Modells als atypisch gilt also z.B. Werte unter 0,05 oder über 0,95 auftreten.

Die Reproduktion der Anzahl der Expansionen und damit einhergehend der Anzahl der Rezessionen ist für alle Modelle schwierig. Keiner der Mediane überschreitet die beobachteten Werte von 7 Expansionen und 6 Rezessionen. Die Werte der Verteilungsfunktionen aller Modelle sind über 0,9. Besonders schlecht schneiden das AR- und das MSIH-Modell ab, die bei 10.000 Wiederholungen de facto nicht in der Lage sind, die entsprechende Anzahl an Zyklen zu erzeugen. Positiv herausheben lassen sich das MSA- und MSAH-Modell sowie das DLR-Modell, deren

Tabelle 3.2: Simulationsergebnisse der BIP-Wachstums-Modelle – Mediane und empirische Verteilungsfunktion

	AR	MSA	MSAH	MSI	MSIH	B-B	FC	SETAR	DLR	BIP
1. # Expansionen	2,000	5,000	5,000	4,000	2,000	4,000	4,000	4,000	5,000	7,000
↪ $F(BIP)$	1,000	0,963	0,944	0,972	1,000	0,980	0,981	0,979	0,954	
2. Dauer der Expansion	69,000	26,200	24,400	30,500	65,000	32,000	31,750	31,000	24,800	17,286
↪ $F(BIP)$	0,001	0,110	0,175	0,090	0,002	0,058	0,063	0,074	0,131	
3. Std. der Dauer	22,189	19,312	17,574	20,704	26,163	21,676	20,817	21,407	17,542	13,659
↪ $F(BIP)$	0,400	0,254	0,316	0,222	0,278	0,214	0,233	0,215	0,293	
4. Höhe der Expansion	3,396	2,561	2,477	2,660	2,991	2,704	2,909	2,612	2,692	2,815
↪ $F(BIP)$	0,054	0,779	0,827	0,660	0,416	0,620	0,392	0,732	0,666	
5. Std. der Höhe	3,440	3,266	3,282	3,417	3,396	3,310	3,628	3,429	3,489	3,553
↪ $F(BIP)$	0,693	0,844	0,783	0,722	0,596	0,815	0,381	0,665	0,614	
	AR	MSA	MSAH	MSI	MSIH	B-B	FC	SETAR	DLR	BIP
6. # Rezessionen	1,000	4,000	4,000	3,000	2,000	3,000	3,000	3,000	4,000	6,000
↪ $F(BIP)$	1,000	0,945	0,916	0,957	1,000	0,970	0,971	0,966	0,933	
7. Dauer der Rezession	3,000	4,500	4,882	4,400	3,333	4,000	4,250	4,500	4,250	3,333
↪ $F(BIP)$	0,617	0,155	0,099	0,197	0,494	0,284	0,222	0,205	0,185	
8. Std. der Dauer	0,000	1,871	2,217	1,862	0,000	1,528	1,633	2,082	1,732	1,033
↪ $F(BIP)$	0,813	0,254	0,173	0,271	0,689	0,355	0,325	0,262	0,240	
9. Tiefe der Rezession	-2,273	-1,722	-1,601	-1,596	-1,836	-2,066	-1,699	-1,673	-1,781	-1,664
↪ $F(BIP)$	0,701	0,552	0,443	0,441	0,569	0,741	0,531	0,508	0,594	
10 Std. der Tiefe	6,401	5,100	4,509	4,990	6,222	6,686	5,493	4,922	5,306	4,454
↪ $F(BIP)$	0,358	0,329	0,484	0,364	0,318	0,146	0,265	0,395	0,280	
	AR	MSA	MSAH	MSI	MSIH	B-B	FC	SETAR	DLR	BIP
11. Tiefe	0,004	-0,001	-0,011	0,002	0,002	-0,101	-0,092	-0,076	0,024	0,345
↪ $F(BIP)$	0,987	0,974	0,943	0,981	0,970	0,988	0,994	0,984	0,979	
12. Steilheit	0,005	0,016	0,113	0,032	0,133	-0,351	0,009	0,038	-0,035	-0,012
↪ $F(BIP)$	0,470	0,442	0,307	0,408	0,292	0,940	0,458	0,408	0,548	
13. Schärfe	0,002	-0,060	0,222	-0,036	-0,052	-1,428	-1,104	0,032	-0,350	-0,048
↪ $F(BIP)$	0,494	0,502	0,441	0,498	0,501	0,701	0,662	0,483	0,550	

In der ersten Zeile wird jeweils der Median der Simulationen und in der zweiten Zeile der Wert der empirischen Verteilungsfunktion an der Stelle des beobachteten Konjunkturzyklus berichtet. Die letzte Spalte unter BIP re-präsentiert den beobachteten Konjunkturzyklus.

Werte der Verteilungsfunktionen für die besagten Kategorien die besten sind. Diese Bewertung wird zusätzlich bestärkt, wenn man die Dauer der Expansionen betrachtet. Die Werte der Verteilungsfunktion der drei besagten Modelle sind sämtlich über 0,1, während AR- und MSIH-Modell Werte nahe null aufweisen. Die mittlere Dauer der Expansionen hängt direkt mit der Anzahl der Rezessionen zusammen. Alle Modelle haben unbedingte Mittelwerte über null, die Expansion ist also das vorwiegende Regime und einzelne Rezessionen können aus letzt genanntem Grund nicht allzu lange andauern, so dass die mittlere Dauer der Expansion wesentlich mit der Anzahl der Expansionen und somit Rezessionen zusammenhängt. Auffällig ist, dass das MSI-Modell, das insbesondere für die Modellierung von Rezessionen Anwendung findet, schlechter abschneidet als das MSAH-Modell oder das DLR-Modell. Die Schätzung des MSI-Modells lässt allerdings auch nicht auf die Interpretation der Zustände als Rezession und Expansion schlussfolgern, vergleiche Abschnitt 2.4.

Bei der Betrachtung der mittleren Dauer der Rezessionen zeigt sich, dass das MSAH-Modell zu relativ langen Rezessionen neigt. Es hat den höchsten Median und der Wert der Verteilungsfunktion erreicht nur 0,099. Dies korrespondiert zwar mit dem betragsmäßig niedrigsten Median bei der Tiefe der Rezessionen (lang andauernd aber weniger harte Rückgänge des BIP), die Verteilungsfunktion nimmt aber immerhin den Wert 0,441 an. Bezüglich der durchschnittlichen Dauer und Tiefe der Rezessionen lassen sich andere Modelle im Hinblick auf die tatsächlich beobachteten Werte kaum differenzieren. Die Standardabweichungen der Dauer und Tiefe bzw. Höhe führen ebenfalls nicht zur Modelldifferenzierung. Die tatsächlich beobachteten Werte finden sich jeweils in der Mitte der Verteilung.

Den positiven Wert der Schiefe der gefilterten Niveauvariable können die verschiedenen Modelle schlecht nachbilden. Alle Verteilungsfunktionen nehmen Werte größer als 0,9 an. Der Median aller Modelle ist nahe null und zum Teil negativ. Am besten schneidet das MSAH-Modell mit 0,943 ab. Bei "Steilheit" und "Schärfe" schneiden nahezu alle Modelle gut ab. Die tatsächlich beobachteten Werte deuten auf Symmetrieeigenschaften der unterstellten Prozesse hin, die angesichts der Medianwerte einiger Modelle zum Beispiel dem AR-Modell oder dem MSI-Modell bzw. deren Schätzungen deutlich werden.¹² Die Modelle, die explizit für Formen von Asymmetrie konstruiert worden sind, wie das Bounce-Back und das Floor-Ceiling-Modell, schneiden erwartungsgemäß am schlechtesten ab. Die Medianwerte beider Modelle bezüglich "Schärfe" sind die höchsten und der Wert der Verteilungsfunktion für das Bounce-Back-Modell bezogen auf die "Steilheit" ist mit 0,94 verglichen mit den anderen Modellen extrem hoch. Doch kann man beide Modelle über diese einzelnen Kriterien kaum verwerfen.

Um eine Möglichkeit zu haben die Kriterien zusammen zu evaluieren haben Hess und Iwata (1997) χ^2 -Tests durchgeführt, wobei die mittleren quadrierten Abweichungen der Simulationen

¹²Die Symmetrieeigenschaften des MSI-Modells sind von den Ausprägungen der Parameter abhängig, vgl. Knüppel (2005).

von den tatsächlich beobachteten Werten über verschiedene Kennzahlen aufsummiert werden. Problematisch an diesem Vorgehen ist, dass eindeutig diskriminierende Kennzahlen in der Gesamtheit die Testentscheidung nicht determinieren, also zum Beispiel für ein Modell die Nullhypothese, dass es die verschiedenen Kennzahlen des Konjunkturzyklus reproduzieren kann, nicht verworfen wird, obwohl dies bei einem (z.B. die Anzahl der Rezessionen) eindeutig der Fall ist. Alternativ werden an dieser Stelle Akzeptanzregionen definiert, die ähnliche Eigenschaften haben wie der tatsächlich beobachtete Konjunkturverlauf. Die Akzeptanzregionen werden wie folgt definiert. Für die Kennzahlen 2., 4., 7. und 11.-13. werden deren Standardabweichungen aus den tatsächlich vorliegenden BIP-Daten geschätzt und basierend auf der Normalverteilungsannahme drei verschiedene Konfidenzintervalle festgelegt, zu 90%, 95% und 99%, wobei das erste am stärksten diskriminiert und das letzte am schwächsten. Für die Kennzahlen 1. und 6., die die Anzahl der Expansionen und Rezessionen repräsentieren werden ebenfalls drei Intervalle festgelegt, die ganzzahlig und symmetrisch um die tatsächlich beobachteten Werte liegen: ± 1 , ± 2 und ± 3 . Die Kennzahlen 3., 5., 8. und 10. werden an dieser Stelle nicht berücksichtigt, da sie augenscheinlich keine diskriminierende Wirkung haben. Damit eine Simulation akzeptiert wird, müssen ihre Kennzahlen in jedes der neun Intervalle fallen. Das Verhältnis zwischen akzeptierten Simulation und Simulationen insgesamt (10.000) ist in Prozent in Tabelle 3.3 dargestellt. Je höher die Verhältniszahl ist, desto besser bzw. desto eher kann das entsprechende Modell die Eigenschaften des Konjunkturzyklus nachbilden.

Es werden verschiedene Szenarien für die Zusammenstellung der Akzeptanzregionen entsprechend der Intervalllängen unterschieden. Ferner werden in Tabelle 3.3 zwei Szenarien angegeben, die mit einem Asterisk markiert sind, in denen die Asymmetriemaße nicht in die Definition der Akzeptanzregion einfließen. Es fällt die insgesamt niedrige Akzeptanzrate auf. Unterstellt man 9 unabhängige Intervalle die jeweils 90% entsprechen, würde man eine Akzeptanzrate des "richtigen" Modells von 38,74% erwarten. Alle Modelle haben also erhebliche Schwierigkeiten die stilisierten Fakten des Konjunkturverlaufs zu reproduzieren. Abgesehen von dieser Gesamtbilanz zeigt das DLR-Modell herausragende Ergebnisse. Die Akzeptanzhäufigkeit ist in allen Szenarien mindestens 50 % höher als die des zweitbesten Modells, welches, sofern die Asymmetriemaße berücksichtigt werden, das MSA-Modell ist. So ist die relative Akzeptanz im restriktivsten Szenario (90% Intervalle und ± 1 Phase) für das DLR-Modell 4,31 % und für das MSA-Modell 2,18%. Im liberalsten Szenario unter Berücksichtigung der Asymmetriemaße (99% Intervalle und ± 3 Phasen) ist die Akzeptanzrate für das DLR bei 21,92% und für das MSA-Modell bei 14,36%. Das AR-Modell kommt in keinem Szenario unter Berücksichtigung der Asymmetriemaße auf über 1%. Ähnlich schlecht sind die Ergebnisse für das MSIH- und das Bounce-Back-Modell.

Werden die Asymmetrien nicht berücksichtigt (siehe die letzten beiden Zeilen in Tabelle 3.3) sind die Akzeptanzraten erwartungsgemäß höher. Die relativen Positionen der Modelle zueinander ändern sich insbesondere im Hinblick auf das Bounce-Back-Modell, das in diesen zwei Szenarien zu den drei besten Modellen zählt. Hier zeigt sich insbesondere, dass das Bounce-Back-

Tabelle 3.3: Simulationsergebnisse der BIP-Wachstums-Modelle – relative Häufigkeit der Akzeptanzregionen in %

	AR	MSA	MSAH	MSI	MSIH	BB	FC	SETAR	DLR
90% / # ± 1	0,04	2,18	1,38	1,61	0,19	0,33	1,24	1,09	4,31
90% / # ± 2	0,23	3,71	2,28	2,71	0,39	0,53	2,19	1,92	6,42
90% / # ± 3	0,23	3,74	2,31	2,73	0,39	0,53	2,19	1,93	6,43
95% / # ± 1	0,04	3,41	2,26	2,58	0,29	0,59	1,96	1,84	6,50
95% / # ± 2	0,41	6,28	3,84	4,89	0,72	1,12	3,99	3,64	10,53
95% / # ± 3	0,41	6,33	3,89	4,94	0,72	1,12	3,99	3,66	10,59
99% / # ± 1	0,10	7,72	5,93	6,20	0,57	1,89	5,02	4,21	12,88
99% / # ± 2	0,74	14,24	9,64	11,77	1,84	3,79	9,90	8,91	21,71
99% / # ± 3	0,74	14,36	9,74	11,88	1,85	3,81	10,04	8,98	21,92
90% / # ± 1 /*	0,25	8,85	8,04	7,84	1,07	8,13	6,70	5,70	14,91
95% / # ± 2 /*	1,32	17,86	15,13	16,57	3,75	18,07	15,10	12,93	27,67

Je höher die Prozentzahl, desto eher ist das Modell in der Lage, den Konjunkturzyklus zu reproduzieren.

Modell zur Modellierung der Asymmetrien der US-Konjunktur entwickelt wurde. Das DLR-Modell erweist sich allerdings auch hier als das relativ beste Modell.

Die Reproduzierbarkeit der Konjunkturzykluseigenschaften ist ein weiterer Test für die Eignung verschiedener Modelle zur Abbildung des BIP. Die Ergebnisse weichen teilweise von den Einsichten, die im Rahmen der Evaluierung der Prognosegüte oder des In-Sample-Fits gemacht worden sind, ab. Es gibt Eigenschaften des deutschen BIP, die von nahezu keinem Modell abgebildet werden können, wie die positive Schiefe der gefilterten Niveauvariablen. Eine wesentliche Einsicht ist, dass das lineare AR-Modell defacto nicht in der Lage ist, den deutschen Konjunkturverlauf nachzubilden.¹³ Von allen Modellen sind im wesentlichen das MSA-, das MSAH- und insbesondere das DLR-Modell hervorzuheben. Diese Modelle weisen bei 10.000 Simulationsläufen mehrere Züge auf, deren Eigenschaften den tatsächlich beobachteten ähnlich sind. Der Umstand, dass das DLR-Modell so gut abschneidet, lässt Spekulationen zu, dass verschiedene Aspekte des DLR-Modells wesentliche Eigenschaften des Konjunkturverlaufs widerspiegeln. Das DLR-Modell kann die Anzahl der Konjunkturzyklen mit am besten nachbilden, was für die Annahme stochastischer Regimeparameter spricht. Diese sind flexibel genug sich den unterschiedlichen Konjunkturtiefen und -höhen anzupassen, während das MSI-Modell bei gleichzeitigen Schwankungen des Trendwachstums im deutschen Fall nicht als Modell zur Differenzierung von Expansionen und Rezessionen angesehen werden kann.

3.5 Die Bedeutung nicht-linearer Zeitreihenmodelle im deutschen Kontext

In diesem und dem vorangegangenen Kapitel werden verschiedene nicht-lineare Zeitreihenmodelle mit einem AR-Modell verglichen. Es werden die Marginalen Likelihoods, die Prognoseeigenschaften sowie die Fähigkeiten der Konjunkturzyklusnachbildung überprüft. Keines der nicht-linearen Modelle erweist sich in allen Aspekten dem AR-Modell überlegen, so dass keine spezielle Form der Nicht-Linearität als eindeutiges Charakteristikum der deutschen BIP-Daten gefunden werden kann. Folglich kann auch keine spezielle Form der Nicht-Linearität benannt werden, die bei der Formulierung von ökonomischen Modellen berücksichtigt werden muss bzw. die von ökonomischen Modellen reproduziert werden muss, damit sie für den deutschen Fall geeignet sind.

Für eine lineare Modellierung des BIP spricht ferner, dass von den diskutierten Maßen von möglichen Asymmetrien kein signifikantes Ergebnis gegen die Annahme eines symmetrischen Prozesses spricht, siehe Abschnitt 3.2. Nimmt man die Ergebnisse aus der In-Sample und Out-

¹³Dieses Ergebnis steht im offenen Widerspruch zu Arbeiten für US-Daten, die das AR-Modell gerade aus der Sicht der Reproduzierbarkeit des Konjunkturzyklus rehabilitieren, siehe Harding und Pagan (2002) oder Engel et al. (2005).

of-Sample-Analyse der Zeitreihenmodelle zusammen, erscheint das AR-Modell als gut geeignet. Auf der einen Seite ist In-Sample das Floor-Ceiling-Modell überlegen, doch fällt dieser Vorteil Out-of-Sample weg und umgekehrt lassen sich die guten Punktprognoseeigenschaften von MSAH und SETAR im Vergleich zum AR-Modell In-Sample nicht bestätigen. Die Überlegenheit des Floor-Ceiling-Modells In-Sample ist offensichtlich der heteroskedastischen Modellierung geschuldet. Heteroskedastie ist allerdings kein Hinweis auf Asymmetrie, so dass diese nicht gegen die Verwendung von VAR-Modellen in der Politikberatung spricht, vgl. Kiani und Bidarkota (2004).

Trotzdem ist die Annahme eines AR-Modells für deutsche BIP-Daten (auch unter Berücksichtigung der Heteroskedastie) problematisch, da die ermittelte autoregressive Dynamik nicht in der Lage ist den aus den deutschen BIP-Daten ermittelten Konjunkturzyklus nachzubilden. Insbesondere die Anzahl der Zyklen ist zu hoch, als dass es plausibel ist, dass sie aus einem AR-Modell stammen. Das gute Abschneiden des DLR-Modells zeigt in die Richtung, dass die deutsche Konjunktur eher in unterschiedliche Regime unterteilt gedacht werden kann. Diese univariaten (reduzierte Form) Ergebnisse deuten für die multivariate Modellierung vielleicht daraufhin, dass ein VAR-Modell mit zeitvariierenden Koeffizienten, wie es Cogley und Sargent (2005) vorschlagen, für die Modellierung deutscher Daten eine gute Wahl ist.

Kapitel 4

Die Verminderung der Volatilität des BIP-Wachstums

4.1 Einleitung

Die Abweichungen zwischen den Ergebnissen der In-Sample und Out-of-Sample Evaluation der Modelle sowie das relativ gute Abschneiden heteroskedastischer Modelle legen die Vermutung nahe, dass der Prozess, der das deutsche BIP-Wachstum erzeugt, strukturellen Veränderungen unterworfen ist. Zugleich ist angesichts der Zeitreihe des BIP-Wachstums in Abbildung 2.3 eine Reduktion der Volatilität augenscheinlich, so dass die Frage nach einem Rückgang der Volatilität in Form eines Strukturbruchs plausibel erscheint. Für die USA hat die Fragestellung, ob und warum es eine Volatilitätsreduktion gegeben hat, ein breites Interesse in der Literatur gefunden. Eine abrupte Volatilitätsreduktion im Jahr 1984 gilt inzwischen als stilisierter Fakt, während die Diskussion um mögliche Ursachen dieser Reduktion noch andauert, siehe z.B. Gali und Gambetti (2007). In diesem Kapitel wird untersucht, ob es einen Strukturbruch in der Volatilität des deutschen BIP-Wachstums gegeben hat und welche Ursachen dabei eine Rolle spielen.¹

Für den deutschen Kontext gibt es eine geringere Anzahl von Untersuchungen, die die Frage einer Volatilitätsreduktion aufgreifen und die zum Teil zu unterschiedlichen Ergebnissen kommen. Im Rahmen einer Analyse von Daten der G 7 berichten Mills und Wang (2003) einen Bruch der bedingten Varianz im Jahr 1974, wobei sie auf Daten ab 1960 zurückgreifen.² Buch et al. (2004) diskutieren einen Volatilitätsrückgang in der Zeit nach der Wiedervereinigung 1990 und die damit möglicherweise verbundenen Ursachen. Analog findet sich in Stock und Watson (2003b) im Rahmen eines Modells stochastischer Volatilität eine Reduktion der bedingten Varianz, die insbesondere in den frühen 90er Jahren forciert auftritt. Im Widerspruch zu diesen

¹Die Darstellung sowie die Ergebnisse folgen einer erweiterten Fassung von Abmann et al. (2006).

²Die Studie von Kähler und Marnet (1994), die die Frage der Volatilitätsreduktion allerdings nicht fokussieren, kommt zu einem ähnlichen Ergebnis.

Ergebnissen finden Fritsche und Kuzin (2005a) für einen etwas anderen Datensatz, dass ein Volatilitätsrückgang mit der Veränderung der autoregressiven Dynamik in den 70er Jahren einhergeht. Sie finden keine Evidenz für eine Reduktion der bedingten Varianz. In der vorliegenden Analyse wird das vollständig revidierte BIP-Wachstum der Jahre 1970 bis 2006 verwendet und mit Bayesianischen Methoden wird überprüft ob und wann ein Strukturbruch in den deutschen Daten vorliegt. Diese Arbeit verwendet daher eine Veröffentlichung des deutschen BIP, die über den gesamten Zeitraum konsistenten Erhebungsmethoden und Datenabgrenzungen folgt. Lange Zeit waren die methodischen Änderungen der Volkswirtschaftlichen Gesamtrechnung Mitte der 90er Jahre nicht für die Jahrzehnte davor zurückverfolgt worden. Außerdem bietet diese Arbeit die erste Bayesianische Analyse der Frage nach einem Strukturbruch der deutschen Volatilität.³ Bayesianische Inferenz über den Strukturbruch bietet im Vergleich zu den klassischen Methoden wie den Tests von Andrews (1993) oder Andrews und Ploberger (1994) eine genauere Möglichkeit der Datierung des Bruchs. Der Bruchpunkt wird als Parameter aufgefasst und seine a posteriori Verteilung ermittelt. Die Strukturbruchanalyse bezieht sich auf die konditionale Varianz. Da diese Analyse von der unterstellten Mittelwertgleichung abhängt, werden neben einem linearen autoregressiven Modell auch ein Markov-Switching-Modell für den Interzept sowie das DLR-Modell berücksichtigt, um die Sensitivität der Ergebnisse gegenüber verschiedenen Mittelwertmodellen zu kontrollieren, vgl. Kim und Nelson (1999a).

Neben der Inferenz über den Bruchpunkt, die in Abschnitt 4.2 diskutiert wird, ist ein weiteres Anliegen mögliche Ursachen für die Volatilitätsreduktion aufzudecken. Verschiedene Erklärungen für Volatilitätsreduktionen werden insbesondere im Zusammenhang mit den USA diskutiert. Neben der Möglichkeit, dass schlicht kleinere Schocks die Ökonomie treffen, schließlich waren die Ölkrise vor 1984, werden eine verbesserte Geldpolitik, Verbesserungen in der Lagerhaltung und der Finanzintermediation sowie der Strukturwandel, der den Schwerpunkt der ökonomischen Aktivität weg von hoch volatilen Komponenten wie der Industrieproduktion zu weniger volatilen Bereichen wie dem Dienstleistungssektor verlagert, diskutiert. In Abschnitt 4.3 werden diese möglichen Ursachen für den deutschen Fall erläutert und mit empirischen Befunden zu den Komponenten des deutschen BIP in Verbindung gebracht. Buch et al. (2004) diskutieren ebenfalls mögliche Ursachen einer Volatilitätsreduktion in Deutschland. An dieser Stelle werden jedoch abweichend von Buch et al. (2004) eine andere Datengrundlage und Bayesianische Methoden verwendet, die schließlich zu teilweise anderen Ergebnissen führen. Der Strukturwandel, der in zwei Dimensionen auftritt, zum einen die Veränderung der Bedeutung der einzelnen Sektoren und zum anderen eine Veränderung der Beziehungen zwischen den Sektoren, ist für einen großen Teil der Volatilitätsreduktion in Deutschland verantwortlich. Im folgenden Abschnitt wird zunächst die Fragen, ob es einen Strukturbruch gab und wenn ja wann, diskutiert.

³Kim und Nelson (1999a) sowie Kim et al. (2004) wenden Bayesianische Methoden zur Analyse des Strukturbruchs in den USA an.

4.2 Auffinden und Datieren des Strukturbruchs

4.2.1 Modellspezifikationen

In der Literatur wird die Frage nach einer abrupten Volatilitätsreduktion häufig mit Tests auf Strukturbruch der bedingten (Fehler-)Varianz untersucht. Dieser Ansatz wird auch hier verfolgt. Dabei werden Bayesianische Verfahren verwendet, die das Modell mit Bruch mit dem Modell ohne Bruch über die Marginale Likelihood vergleichen. Kim und Nelson (1999a) weisen darauf hin, dass bei der Analyse der bedingten Varianz auf Strukturbruch das unterstellte Mittelwertmodell Einfluss nehmen kann auf die Entscheidung, ob ein Strukturbruch gefunden hat sowie auf seine Datierung. Um in diesem Sinne die Sensitivität der Ergebnisse zu überprüfen werden verschiedene Mittelwertmodelle unterstellt, die eine Auswahl der Modelle aus Kapitel 2 darstellen. Als erstes Modell wird das lineare autoregressive Modell mit vier Verzögerten angenommen:

$$y_t = \mu + \sum_{\ell=1}^k \phi_{\ell} y_{t-\ell} + \epsilon_t, \quad \epsilon_t \sim \mathcal{N}(0, \sigma_{d_t}^2), \quad (4.1)$$

wobei im Fall eines Bruchs in der Varianz die Fehlervarianz $\sigma_{d_t}^2$ von der Zustandsvariable d_t abhängt und d_t bis zum Zeitpunkt des Bruchs t^* den Wert 0 annimmt und nach dem Bruch den Wert 1. Analog zu Kim und Nelson (1999a) wird für die Zustandsvariable d_t angenommen, dass sie einer restringierten Markov-Kette mit zwei Zuständen und den folgenden Übergangswahrscheinlichkeiten folgt:

$$P(d_{t+1} = 0 | d_t = 0) = v, \quad P(d_{t+1} = 1 | d_t = 1) = 1, \quad v \in (0, 1). \quad (4.2)$$

Das Modell mit Bruch in der Varianz in Gleichung 4.1 wird mit einem Modell ohne Bruch verglichen, das sich aus dem Bruchmodell ergibt, wenn $\sigma_0^2 = \sigma_1^2$.

Fritsche und Kuzin (2005a) argumentieren, dass die Volatilitätsreduktion auf eine Veränderung der autoregressiven Dynamik zurückzuführen ist. Daher wird neben dem Modell 4.1 ein AR-Modell mit Bruch in den Mittelwertparametern berücksichtigt:

$$y_t = \mu_{d_t} + \sum_{\ell=1}^k \phi_{\ell, d_t} y_{t-\ell} + \epsilon_t, \quad \epsilon_t \sim \mathcal{N}(0, \sigma^2). \quad (4.3)$$

Im Folgenden wird das AR-Modell ohne Bruch als $\mathcal{M}_{AR,0}$, das AR-Modell mit Varianzbruch als $\mathcal{M}_{AR,1}$ und das AR-Modell mit Bruch in den Mittelwertparametern als $\mathcal{M}_{AR,2}$ bezeichnet. Die Analyse wird mit Methoden der Bayesianischen Statistik durchgeführt. Für die Modellevaluation werden die Marginalen Likelihoods mit dem in Abschnitt 2.5 beschriebenen Verfahren ermittelt. Der Gibbs-Sampler, der im Fall eines Modells mit Strukturbruch verwendet wird, wird in Anhang A.4 dargestellt.

Für die Analyse des Varianzbruchs wird neben dem AR-Modell ein Markov-Switching-Modell für den Interzept als alternatives Mittelwertmodell angenommen, vergleiche Abschnitt 2.1.2.

Durch die Annahme dieses Modells kann berücksichtigt werden, dass die Volatilitätsreduktion eventuell nicht durch eine Reduktion der bedingten Varianz, sondern durch eine Änderung der Konjunkturzyklusabfolge oder der Trendwechsel erklärt werden kann. Analog zu Kim und Nelson (1999a) wird zusätzlich die Möglichkeit berücksichtigt, dass die beiden Zustände durch den Bruch näher aneinander rücken also die Konjunkturamplitude geringer und somit die Volatilität reduziert wird. Dies wird dadurch modelliert, dass der Strukturbruch auch auf die Interzeptparameter angewendet wird:

$$g_t = \bar{\mu}_{s_t, d_t} + \sum_{\ell=1}^k \phi_{\ell} g_{t-\ell} + \epsilon_t, \quad \epsilon_t \sim \mathcal{N}(0, \sigma_{d_t}^2). \quad (4.4)$$

Die Zustandsvariable s_t folgt einer Markov-Kette mit zwei Zustände wie es auch in den Modellen in Abschnitt 2.1.2 der Fall ist. Die verschiedenen Markov-Switching-Modelle, die zur Analyse des Strukturbruchs herangezogen werden, lassen sich wie folgt unterscheiden:

$$\begin{aligned} \mathcal{M}_{MS,0} &: \mu_{00} = \mu_{01} \quad \text{and} \quad \mu_{10} = \mu_{11} \quad \text{and} \quad \sigma_0^2 = \sigma_1^2 \\ \mathcal{M}_{MS,1} &: \mu_{00} = \mu_{01} \quad \text{and} \quad \mu_{10} = \mu_{11} \quad \text{and} \quad \sigma_0^2 \neq \sigma_1^2 \\ \mathcal{M}_{MS,2} &: \mu_{00} \neq \mu_{01} \quad \text{and} \quad \mu_{10} \neq \mu_{11} \quad \text{and} \quad \sigma_0^2 \neq \sigma_1^2, \end{aligned}$$

wobei μ_{00} den Parameter des Regimes 0 vor dem Bruch und μ_{01} des Parameter des Regimes 0 nach dem Bruch darstellt. Analoges gilt für die Parameter μ_{10} und μ_{11} des Regimes 1. Der Bruch ist im Hinblick auf die Mittelwertparameter nur in $\mathcal{M}_{MS,2}$ wirksam.

Im Modell $\mathcal{M}_{MS,0}$ wird ein einfaches Markov-Switching-Modell (MSI), wie es auch in Kapitel 2 und 3 Anwendung findet, unterstellt. Modell $\mathcal{M}_{MS,1}$ berücksichtigt einen Bruch in der Fehlervarianz und Modell $\mathcal{M}_{MS,2}$ spezifiziert zusätzlich, dass sich der Bruch auf die Mittelwerte der beiden Zustände auswirkt. Die Volatilität wird ebenfalls durch die Differenz zwischen den Mittelwerten der beiden Zustände beeinflusst. Wenn die Konjunkturphasen näher zusammenrücken, also die Rezessionen weniger tief und die Aufschwünge weniger stark werden, entspricht dies auch einem Volatilitätsrückgang. Ein weiteres mögliches Modell, in dem der Bruch ausschließlich auf die beiden Mittelwertparameter wirkt, bei dem also die Volatilitätsreduktion durch eine Änderung der Mittelwertparameter (Reduktion der Differenz zwischen den Zuständen) erklärt werden könnte, wird an dieser Stelle nicht weiter betrachtet, da die Ergebnisse zu diesem Modell in allen Szenarien schlechter ausfallen als die für $\mathcal{M}_{MS,0}$.

Als dritter Modelltyp wird das DLR-Modell berücksichtigt. Im Vergleich zum Modell, das in Abschnitt 2.1.6 erläutert wird, werden an dieser Stelle einige Modifikationen vorgenommen. Da das DLR-Modell hier nicht zur Vorhersage genutzt werden soll und daher Aussagen über zukünftige Regime nicht nötig sind, werden die Regimeparameter a_j und b_j als Modellparameter und nicht als Realisationen eines Zufallsprozesses interpretiert. Ferner wird die Anzahl der Regime auf neun fixiert, was der Anzahl an Regimen in der konditionalen Schätzung entspricht.

Tabelle 4.1: Log Marginale Likelihoods

		Prior (I)	Prior (II)	Prior (III)
AR-model	$\ln[f(G_T \mathcal{M}_{AR,0})]$	-394.33	-393.42	-392.79
	$\ln[f(G_T \mathcal{M}_{AR,1})]$	-391.15	-389.56	-388.33
	$\ln[f(G_T \mathcal{M}_{AR,2})]$	-406.37	-406.11	-402.31
MS-model	$\ln[f(G_T \mathcal{M}_{MS,0})]$	-395.18	-394.40	-391.73
	$\ln[f(G_T \mathcal{M}_{MS,1})]$	-393.34	-392.22	-389.11
	$\ln[f(G_T \mathcal{M}_{MS,2})]$	-394.38	-393.28	-389.98
DLR-model	$\ln[f(G_T \mathcal{M}_{DLR,0})]$	-390.17	-384.16	-385.08
	$\ln[f(G_T \mathcal{M}_{DLR,1})]$	-384.48	-380.64	-378.44

Die Regimewechelpunkte werden jedoch nicht analog zur konditionalen Schätzung festgelegt, sondern werden in dieser Modellversion als latente Variablen aufgefasst und im Gibbs-Sampler mitgezogen insbesondere um einen möglichen Einfluss des Bruchs in der Varianz auf die Mittelwertspezifikation zuzulassen. Der korrespondierende Gibbs-Sampler für das modifizierte DLR-Modell ist in Appendix A.4 dargestellt. Die Regimeparameter und die Regimewechsel stehen im direkten Verhältnis zur Volatilität. Volatilitätsrückgänge können als verringerte Steigungen der Regimetrends oder als seltenere Regimewechsel auftreten. Für das modifizierte DLR-Modell wird ein Modell mit konstanter Fehlervarianz $\mathcal{M}_{DLR,0}$ und ein Modell mit Bruch in der Fehlervarianz analysiert $\mathcal{M}_{DLR,1}$.

4.2.2 Ergebnisse

Die Ergebnisse für die verschiedenen Modelle der BIP-Wachstumszeitreihe werden mit Hilfe der in Anhang A.4 dargestellten Gibbs-Sampler ermittelt. Die für die Marginalen Likelihoods notwendigen a posteriori Verteilungen werden mit dem in Abschnitt 2.5 erläuterten Verfahren von Chib (1995) berechnet. Um die Sensitivität gegenüber den a priori Annahmen zu berücksichtigen werden Ergebnisse für drei verschiedene Parameterspezifikationen der a priori Verteilungen ermittelt. Die verschiedenen Prior sind in Tabelle A.2 im Anhang gegeben. Tabelle 4.1 gibt einen Überblick über die Modellevidenz in Form der Marginalen Likelihoodwerte für die verschiedenen Modelle und Priorspezifikationen. Im Folgenden werden die Ergebnisse nach Modelltypen gegliedert dargestellt.

Lineare autoregressive Modelle

Entsprechend der Marginalen Likelihood ist für alle Priorspezifikationen in der Klasse der linearen autoregressiven Modelle das Modell mit einem Bruch in der Varianz ($\mathcal{M}_{AR,1}$) sowohl

Tabelle 4.2: Bayesianische Schätzung des AR-Modells mit Bruch in der Varianz

Parameter	Prior		Posterior		
	Mittel	Std. abw.	Mittel	Std. abw.	95%-Bänder
μ	0	$\sqrt{10}$	1.257	.388	[.518 ; 2.015]
ϕ_1	0	$\sqrt{10}$.010	.084	[-.155 ; .176]
ϕ_2	0	$\sqrt{10}$.043	.081	[-.116 ; .204]
ϕ_3	0	$\sqrt{10}$.073	.083	[-.089 ; .236]
ϕ_4	0	$\sqrt{10}$.208	.081	[.050 ; .372]
$1/\sigma_0^2$.100	.707	.0649	.0105	[.0460 ; .0866]
$1/\sigma_1^2$.100	.707	.2262	.0924	[.1237 ; .4896]
σ_0^2			15.814	2.625	[11.554 ; 21.740]
σ_1^2			4.919	1.471	[2.042 ; 8.087]
ν	.976	.051	.989	.011	[.961 ; 0.999]
Bruch			1995:II	12.024	[1992:I ; 2002:II]
Log Marginale Likelihood $\ln f(G_T \mathcal{M}_{AR,1})$					-391.15
Log Bayes Faktor $\ln[f(G_T \mathcal{M}_{AR,1})/f(G_T \mathcal{M}_{AR,0})]$					3.18

Hinweis: Das Modell ($\mathcal{M}_{AR,1}$) wird in den Gleichungen (4.1) und (4.2) beschrieben. Die Momente der a posteriori Verteilung basieren auf 10.000 Gibbs-Iterationen, wobei die ersten 2000 nicht berücksichtigt werden. Die Ergebnisse gelten für das Priorszenario I , siehe Tabelle A.2.

dem Modell ohne Bruch ($\mathcal{M}_{AR,1}$) als auch den Modellen mit abweichenden Ausprägungen des Bruchs vorzuziehen. Insbesondere die von Fritsche und Kuzin (2005a) diskutierte Möglichkeit eines Bruchs in der autoregressiven Dynamik ($\mathcal{M}_{AR,2}$) findet keine Bestätigung in den Daten. Wenn eine autoregressive Struktur für den Mittelwert angenommen wird, findet sich also Evidenz für einen Bruch in der Fehlervarianz im Gegensatz zur Annahme der Strukturstabilität und auch im Gegensatz zur Annahme, dass die Volatilitätsreduktion durch Veränderungen der Mittelwertparameter des autoregressiven Modells verantwortet wird.

Die Bayesianischen Schätzungen für das Priorszenario I des in dieser Modellklasse besten Modells $\mathcal{M}_{AR,1}$ sind in Tabelle 4.2 angegeben. Ferner ist die a posteriori Verteilung des Bruchs in Abbildung 4.1 oben dargestellt. Der Mittelwert der a posteriori Verteilungen der Varianzen hat sich um 69 % durch den Bruch verringert. Eine ähnlich starke Reduktion finden Kim et al. (2004) auch für die US Daten. Der Mittelwert der Bruchverteilung liegt mit 1995:III jedoch ungefähr 10 Jahre nach dem für die USA berichteten Bruchpunkt in 1984. Der Modus der Bruchverteilung ist mit 1993:I etwas vor dem Mittelwert der a posteriori Verteilung anzusiedeln. Wahrscheinlichkeitsmasse für den Bruch gibt es ausschließlich ab 1991, wobei sich neben dem Modus Ende 1992 einige Masse 1996 findet und in geringerem Ausmaß auch noch nach 2000.

Markov-Switching-Modelle

Für die Markov-Switching-Modelle ergibt sich ein ähnliches Bild wie für die linear autoregressiven Modelle. Die Variante mit einem Bruch in der Fehlervarianz ($\mathcal{M}_{MS,1}$) wird für alle Szenarien der Variante ohne Bruch $\mathcal{M}_{MS,0}$ und der Variante, bei der sich der Bruch auch auf die Mittelwertparameter auswirkt ($\mathcal{M}_{MS,2}$), vorgezogen, siehe Tabelle 4.1. Die Abstände zwischen den Modellvarianten sind jedoch für die Markov-Switching-Modellklasse geringer. Also ist die Evidenz für das Modell mit einem Bruch in der Fehlervarianz weniger ausgeprägt als bei den AR-Modellen. Das Ergebnis, dass es keine Evidenz gibt, dass die Differenz der Mittelwerte der Zustände einen Einfluss auf die Volatilitätsreduktion haben, steht im Widerspruch zu dem, was Kim und Nelson (1999a) für die USA finden. Dort wird durch den Bruch 1984 auch die Differenz zwischen Expansionen und Kontraktionen im Verlauf des Konjunkturzyklus geringer. Hierbei mag es eine Rolle spielen, dass das Markov-Switching-Modell für Deutschland weniger Konjunkturphasen, wie es für die USA gelingt, als vielmehr unterschiedliche Trendentwicklungen differenziert. Außerdem ist das Markov-Switching-Modell kein evident besseres Modell als das lineare autoregressive Modell, wie bereits in Kapitel 2 dargelegt wurde.

Die Ergebnisse der Bayesianischen Schätzung gegeben Priorszenario I für das beste Markov-Switching-Modell $\mathcal{M}_{MS,1}$ sind in Tabelle 4.3 dargestellt. Interessanterweise ist die Reduktion des a posteriori Mittelwerts der Varianz durch den Bruch mit 82 % sogar höher als im AR-Modell, was eventuell im Zusammenspiel mit den unterschiedlichen Regimen eine Erklärung findet. Die Datierung des Varianzbruchs ist analog zum zuvor besprochenen Fall. Der Modus ist 1993:I,

Tabelle 4.3: Bayesianische Schätzung des MS-Modells mit Bruch in der Varianz

Parameter	Prior		Posterior		
	Mittel	Std. abw.	Mittel	Std. abw.	95%-Bänder
μ_1	3.499	2.248	2.684	0.611	[1.442 ; 3.846]
μ_0	-2.397	1.943	-0.631	0.472	[-1.624 ; 0.069]
ϕ_1	0	$\sqrt{10}$	-0.082	0.094	[-0.257 ; 0.110]
ϕ_2	0	$\sqrt{10}$	0.035	0.078	[-0.121 ; 0.185]
ϕ_3	0	$\sqrt{10}$	0.109	0.078	[-0.043 ; 0.263]
ϕ_4	0	$\sqrt{10}$	0.221	0.074	[0.078 ; 0.371]
$1/\sigma_0^2$.100	.707	0.081	0.016	[0.054 ; 0.116]
$1/\sigma_1^2$.100	.707	0.608	0.434	[0.198 ; 1.842]
σ_0^2			12.765	2.526	[8.615 ; 18.515]
σ_1^2			2.231	1.141	[0.542 ; 5.046]
v	.976	.051	0.988	0.010	[0.961 ; 0.999]
p	.750	.144	.772	.096	[0.554 ; 0.932]
q	.750	.144	.671	.110	[0.439 ; 0.866]
Bruch			1995:I	11.882	[1991:I ; 2000:IV]
Log Marginale Likelihood $\ln f(G_T \mathcal{M}_{MS,1})$					-393.34
Log Bayes Faktor $\ln[f(G_T \mathcal{M}_{MS,1})/f(G_T \mathcal{M}_{MS,0})]$					1.84

Hinweis: Die Modellgleichung von $(\mathcal{M}_{MS,1})$ ist in Gleichungen (4.4) angegeben. Die Momente der a posteriori Verteilung basieren auf 10.000 Gibbs Iterationen, wobei die ersten 2000 nicht berücksichtigt werden. Die Ergebnisse gelten für das Priorszenario I , siehe Tabelle A.2.

siehe Abbildung 4.1 mitte. Im Wesentlichen werden die Ergebnisse des AR-Modells durch die Ergebnisse des MS-Modells bestätigt.

DLR-Modelle

Die Ergebnisse für die Modelle $\mathcal{M}_{DLR,0}$ und $\mathcal{M}_{DLR,1}$ unterstützen ebenfalls die Hypothese eines Bruchs in der Fehlervarianz. Für alle Priorszenarien ist die Marginale Likelihood des Modells mit Bruch höher als die ohne Bruch und die log-Differenzen teilweise sogar höher als für die AR-Modelle. Zum Vergleich der Marginalen Likelihoods über die unterschiedlichen Modellklassen hinweg ist an dieser Stelle zu sagen, dass das DLR-Modell hier (Tabelle 4.1) im Vergleich mit den AR- und MS-Modellen zwar am besten abschneidet, aber dem DLR-Modell mit der Annahme von neun Regimen a priori Informationen zukommen, die einen direkten Modellvergleich problematisch machen und auch die Unterschiede zu den Ergebnissen in Kapitel 2 erklären.

Für das Modell $\mathcal{M}_{DLR,1}$ sind die Ergebnisse der Bayesianischen Schätzung in Tabelle 4.4 angegeben und die korrespondierende a posteriori Verteilung des Bruchs findet sich in Abbildung 4.1. Mit dem Bruch geht eine Reduktion des Mittelwerts der a posteriori Verteilungen der Fehlervarianz von 79 % einher. Im Unterschied zu den AR- und MS-Modellen ist der Mittelwert der Bruchverteilung nicht in 1995 sondern später im dritten Quartal 1997, wobei der Modus der Verteilung im Jahr 1999 und nicht wie im AR-Modell in 1992 liegt, im DLR-Modell der Bruch also später angenommen werden kann. Diese Verschiebung des Bruchs im Vergleich zum AR-Modell lässt sich durch die Besonderheit des DLR-Modells erklären. Zu Beginn der 90er Jahre setzt ein relativ lang andauerndes expansives Regime ein, das einen geringeren Trendanstieg als andere expansive Phasen und ein a_j hat, dessen 95% Band der a posteriori Verteilung die null einschließt. Die Volatilitätsreduktion zu Beginn der 90er Jahre, die im AR-Modell als Varianzbruch wiedergegeben wird, findet im DLR-Modell zunächst ihren Ausdruck in den Eigenschaften des siebten Regimes, dessen Ende in zeitlicher Nähe zum Modus der a posteriori Verteilung des Bruchs im DLR-Modell liegt. Zu dem Zeitpunkt als sich die Regimedynamik änderte und wieder volatiler wurde, zeigt sich die Volatilitätsreduktion im DLR-Modell auch als Bruch in der Fehlervarianz.

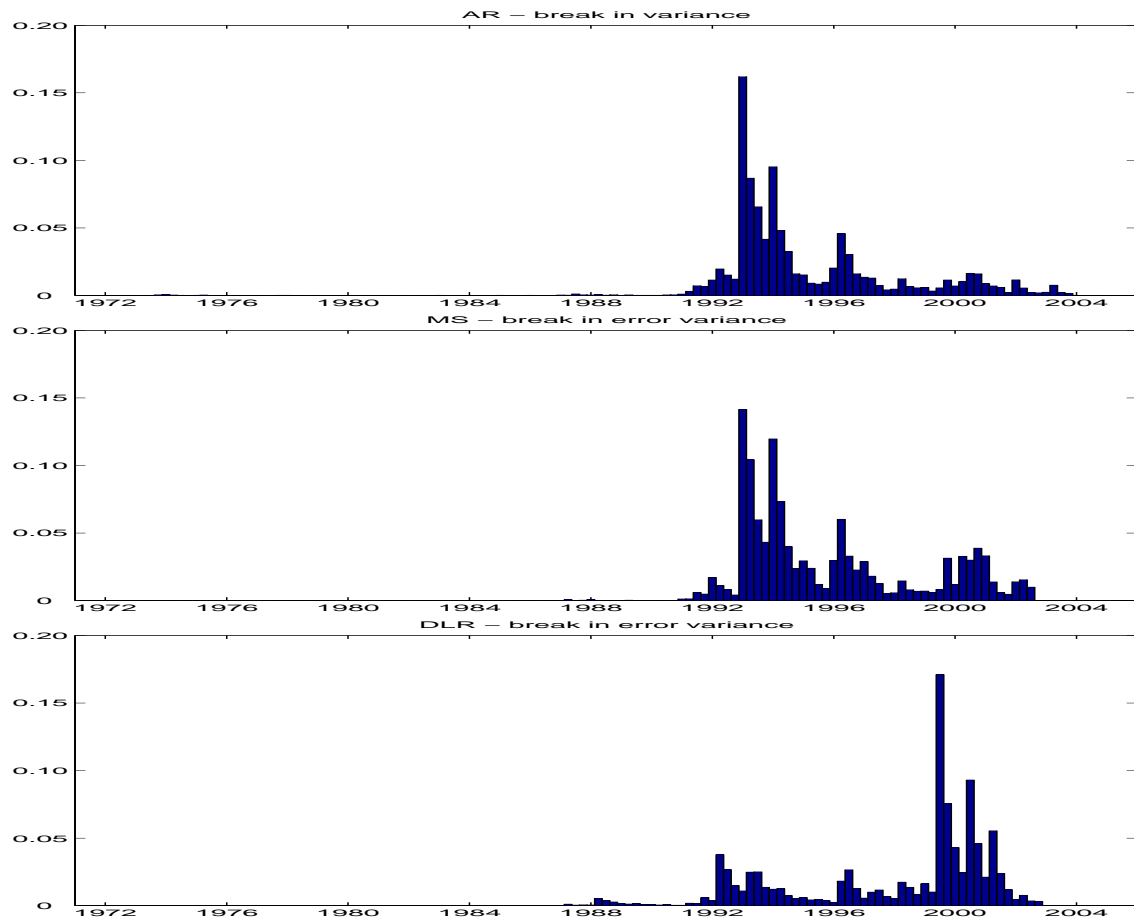
Alle Modelle weisen Evidenz für eine Volatilitätsreduktion auf, die sich als Rückgang der bedingten Varianz äußert. Durch die besondere Mittelwertstruktur des DLR-Modells, die zeitweise (also Mitte des 90er Jahre) einen Teil der Volatilitätsreduktion erklärt, wird hier der Bruch der bedingten Varianz im Modus auf 1999 und damit später als im AR- oder MS-Modell geschätzt, die den Bruch in 1993 ansiedeln.

Tabelle 4.4: Bayesianische Schätzung des DLR-Modells mit Bruch in der Varianz

Parameter	Prior		Posterior		
	Mittel	Std. abw.	Mittel	Std. abw.	95%-Bänder
ν	0	$\sqrt{10}$	-,4568	,1435	[-,7395 ; -,1768]
γ	0	$\sqrt{10}$,1917	,1407	[-,0838 ; ,4677]
a_1	0	$\sqrt{10}$	1,7912	1,5613	[-1,4322 ; 4,6579]
a_2	0	$\sqrt{10}$	2,4457	2,1966	[-1,9287 ; 6,6763]
a_3	0	$\sqrt{10}$,4471	1,6781	[-3,6239 ; 3,1268]
a_4	0	$\sqrt{10}$	1,2977	2,2276	[-2,8423 ; 5,5759]
a_5	0	$\sqrt{10}$	-2,295	1,5347	[-5,3454 ; ,5305]
a_6	0	$\sqrt{10}$	1,9624	2,5633	[-2,1374 ; 7,6347]
a_7	0	$\sqrt{10}$	-1,7975	1,1481	[-4,1652 ; ,4012]
a_8	0	$\sqrt{10}$,3814	1,665	[-2,6702 ; 3,7752]
a_9	0	$\sqrt{10}$	-3,9479	1,1308	[-6,1334 ; -1,6731]
b_1	2,523	1,906	,3441	,2416	[,0237 ; ,928]
b_2	2,523	1,906	1,3235	,4772	[,4434 ; 2,2831]
b_3	2,523	1,906	,2227	,5648	[,0123 ; 2,1976]
b_4	2,523	1,906	,5283	,6393	[,0707 ; 2,6233]
b_5	2,523	1,906	,202	,0687	[,0598 ; ,3313]
b_6	2,523	1,906	,8449	,4926	[,0211 ; 1,7714]
b_7	2,523	1,906	,0928	,2875	[,0045 ; 1,1308]
b_8	2,523	1,906	,5281	,251	[,0933 ; 1,109]
b_9	2,523	1,906	,2832	,1506	[,0568 ; ,599]
β_0	0	$\sqrt{10}$	-2,3919	,4541	[-3,3682 ; -1,6242]
β_1	0	$\sqrt{10}$,2019	,0676	[,0721 ; ,3399]
$1/\sigma_1^2$,1	,707	,0822	,0137	[,0577 ; ,1109]
$1/\sigma_2^2$,1	,707	,4679	,2776	[,1737 ; 1,1634]
σ_1^2			12,4271	2,1511	[9,0171 ; 17,3439]
σ_2^2			2,5542	1,3971	[,8595 ; 5,7585]
v	,976	,051	,9897	,0094	[,9652 ; ,9996]
Bruch			1997:III	13.6884	[1990:IV ; 2001:III]
Log Marginale Likelihood $\ln[f(G_T \mathcal{M}_{DLR,1})]$				-384.4810	
Log Bayes Faktor $\ln[f(G_T \mathcal{M}_{DLR,1})/f(G_T \mathcal{M}_{DLR,0})]$				5.6862	

Hinweis: Das Modell ($\mathcal{M}_{DLR,1}$) ist eine Modifikation des in Abschnitt 2.1.6 dargestellten Modells. Die Momente der a posteriori Verteilung basieren auf 10.000 Gibbs-Iterationen, wobei die ersten 2000 nicht berücksichtigt werden. Die Ergebnisse gelten für das Priorszenario I , siehe Tabelle A.2.

Abbildung 4.1: A posteriori Verteilungen des Bruchs



Histogramme der Bruchpunkte: AR Model (obere Tafel); MS Model (mittlere Tafel); DLR-Model (untere Tafel). Die Ergebnisse basieren auf Priorszenario I, siehe Tabelle A.2.

4.3 Ursachen für die Volatilitätsreduktion

An die Ergebnisse des Abschnitts 4.2 schließt sich die Frage an, welche Ursachen für den Rückgang der Volatilität, der nach 1993 in Deutschland stattgefunden hat, verantwortlich sind. Für den Volatilitätsrückgang in den USA existiert eine umfangreiche Literatur die eine Vielzahl möglicher Ursachen diskutiert. Stock und Watson (2002a) bieten einen Überblick und argumentieren, dass insbesondere der Umstand, dass die US-Ökonomie nach 1984 nicht mehr von starken Schocks wie den Öl-Krisen getroffen wurde, eine große Rolle spielt. Neben diesem Argument, dass es sich bei der Volatilitätsreduktion sozusagen um Glück handelt, werden der Einfluss einer verbesserten Geldpolitik, Neuerungen der Lagerhaltungstechnik und in der Finanzintermediation sowie im Zuge der aufkommenden Dienstleistungsgesellschaft der strukturelle Wandel als mögliche Ursachen genannt. Für den Fall der Volatilitätsreduktion in Deutschland gehen Buch et al. (2004) auf diese möglichen Ursachen ein. Auch wenn sie strukturellen Veränderungen eine Rolle zuschreiben, schließen die Autoren weder eine verbesserte Geldpolitik noch das Argument Glück aus.

An dieser Stelle werden die Ursachen des Volatilitätsrückgangs in Deutschland mit Hilfe Bayesianischer Methoden analysiert. Zum einen wird die Volatilität der Wachstumsraten der einzelnen Komponenten des BIP-Wachstums und zum anderen der Einfluss möglicher Veränderungen der Zusammensetzung der Komponenten untersucht. Das BIP wird vom Statistischen Bundesamt in drei verschiedenen Weisen in Komponenten gegliedert. Von Komponenten wird im Sinne der Entstehung, Verwendung und Verteilung gesprochen. Im folgenden Untersuchungsgang werden die Komponenten der Entstehung wie produzierendes Gewerbe, Landwirtschaft usw. und der Verwendung wie Konsum, Investitionen usw. berücksichtigt.

Die Zerlegung der Varianz des BIP-Wachstums entsprechend der Komponenten des BIP ermöglicht es sowohl die Volatilität der einzelnen Komponenten wie auch Veränderungen in der Zusammensetzung des BIPs wie auch der Korrelation der Komponenten zu berücksichtigen. Das BIP-Wachstum lässt sich nämlich wie folgt zerlegen:

$$y_t = \sum_{i=1}^n a_{it}x_{it}, \quad (4.5)$$

wobei x_{it} die Wachstumsrate der i ten Komponente und a_{it} der korrespondierende Beitrag zur Niveauvariablen sind. Die Varianz des BIP-Wachstums, also des Wachstums des Aggregats ergibt sich als:

$$\text{Var}[y_t] = \sum_{i=1}^n a_{it}^2 \text{Var}[x_{it}] + 2 \sum_{i>j}^n a_{it}a_{jt} \text{Cov}[x_{it}, x_{jt}]. \quad (4.6)$$

Eine Varianzreduktion des BIP-Wachstums entspricht entweder einer Varianzreduktion der Komponenten ($\text{Var}(x_{it})$), die im folgenden Abschnitt 4.3.1 untersucht wird, oder einer Reduktion

der Kovarianz zwischen den Komponenten oder einer Verringerung des Gewichts hoch volatiler Komponenten. Die beiden letzten Aspekte werden in Abschnitt 4.3.2 angesprochen.

Die Analyse der Volatilität der Komponenten lässt Rückschlüsse über einige der möglichen Ursachen der Volatilitätsreduktion im Aggregat zu. So sollten Verbesserungen in der Geldpolitik und Glück als mögliche Ursachen zu Reduktionen der Volatilität in einer oder eher sogar mehreren Komponenten auf der Entstehungsseite führen, vgl. Kim et al. (2004). Ebenso sollten technische Innovationen im Bereich der Lagerhaltung zumindest als Volatilitätsrückgang im produzierenden Gewerbe sichtbar werden. Im Gegenzug lässt sich die Hypothese des Strukturwandels in der Ökonomie von hoch volatilen hin zu weniger volatilen Sektoren direkt mit der Veränderung der Gewichte a_{it} in Verbindung bringen. Außerdem kann der Strukturwandel Einfluss auf die Korrelation zwischen den Sektoren nehmen, wobei im Zusammenhang mit der sektoralen Korrelation auch Entwicklungen im Bereich der Finanzintermediation eine Rolle spielen könnten.

4.3.1 Volatilität der Komponenten des BIP

Das Statistische Bundesamt veröffentlicht mit dem BIP auch dessen Gliederung in Komponenten, wobei dies für drei Gliederungsarten getan wird: 1. Entstehung, 2. Verwendung und 3. Verteilung. Von besonderem Interesse ist an dieser Stelle die Gliederung im Sinne der Entstehung des BIP, da sich mit diesen Komponenten einige der Hypothesen zur Volatilitätsreduktion verknüpfen lassen. Die Datenveröffentlichung, auf der die Arbeit an dieser Stelle basiert, ist identisch mit den Daten, die in Kapitel 2 und 3 verwendet werden. Folgende Komponenten werden auf der Entstehungsseite unterschieden: Land-, Forst- und Fischereiwirtschaft (im Folgenden Landwirtschaft), produzierendes Gewerbe, Baugewerbe, Handel und Verkehr, Finanz- und andere Dienstleistungen (im Folgenden Finanzwirtschaft), öffentliche und private Dienstleistungen (im Folgenden Dienstleistungen). Neben der Entstehungsseite wird an dieser Stelle auch die Verwendungsseite beleuchtet, die sich in Privater Konsum, Staatskonsum, Investitionen, Exporte und Importe gliedert. Ist die Untersuchung der Komponenten auf der Entstehungsseite angelehnt an die Arbeiten für die USA insbesondere für die Frage nach möglichen Ursachen interessant, spielt bei der Analyse der Komponenten auf der Verwendungsseite auch die Frage der Folgen der Volatilitätsreduktion eine Rolle.

Tabelle 4.5 gibt einen Überblick über die Mittelwerte und Standardabweichungen der Wachstumsraten der Komponenten, wobei der gesamte Zeitraum zwischen 1971 und 2006 sowie die beiden durch den Jahreswechsel 1992/1993 getrennten Zeiträume betrachtet werden.

Die Wachstumsraten des BIP haben vor 1993 unbedingt nahezu die doppelte Standardabweichung als nach 1993. Eine solch starke Reduktion der Standardabweichung ist in keiner der Komponenten zu finden, weder auf der Entstehungs- noch auf der Verwendungsseite. Auf der Entstehungsseite steigt die Volatilität sogar bei einigen Komponenten, wie der Landwirtschaft

Tabelle 4.5: Stichprobenstatistiken des BIP-Wachstums und der Komponenten

	Mittelwert			Standardabweichung		
	gesamt	vor 1993	nach 1993	gesamt	vor 1993	nach 1993
BIP	2,2513	2,7440	1,4211	3,7992	4,3991	2,2883

	Entstehungsseite					
	Mittelwert			Standardabweichung		
	gesamt	vor 1993	nach 1993	gesamt	vor 1993	nach 1993
Landwirtschaft	1,2334	1,2384	1,2249	12,1240	9,2074	15,9816
prod. Gewerbe	1,4552	1,4397	1,4813	6,3683	7,0504	5,0769
Baugewerbe	0,0488	1,4379	-2,2921	17,6801	19,5375	13,8634
Handel/Verkehr	2,5990	2,9409	2,0229	5,4385	5,9302	4,4837
Finanz	3,9840	4,7263	2,7330	3,2389	2,5810	3,8275
Dienstleistungen	2,5057	3,2880	1,1875	2,3789	2,3811	1,7107

	Verwendungsseite					
	Mittelwert			Standardabweichung		
	gesamt	vor 1993	nach 1993	gesamt	vor 1993	nach 1993
Privater Konsum	2,2519	3,0062	0,9807	4,2178	4,5978	3,1325
Staatskonsum	2,2532	3,0011	0,9927	5,3291	5,7424	4,3110
Investment	1,7260	2,2550	0,8344	14,8119	15,5380	13,5949
Exporte	5,5433	4,6771	7,0031	11,9331	13,7005	8,0433
Importe	5,0755	4,7190	5,6763	8,8745	9,3707	8,0176

Tabelle 4.6: Log-Bayes-Faktoren für Varianzbrüche in den Komponenten

Verwendungsseite		Entstehungsseite	
Priv. Konsum	.366	Landwirtschaft	9.576*
Staatskonsum	-2.089	prod. Gewerbe	-2.001
Investment	-4.823	Baugewerbe	-1.035
Exporte	-3.958	Handel/Verkehr	-4.289
Importe	-3.969	Finanz	-2.399
		Dienstleistung	-3.454

Hinweis: Die logarithmierten Bayes-Faktoren ergeben sich aus $\ln[f(\{y_t\}_{t=1}^T|\mathcal{M}_{AR,1})/f(\{y_t\}_{t=1}^T|\mathcal{M}_{AR,0})]$. Die Modelle $\mathcal{M}_{AR,1}$ und $\mathcal{M}_{AR,0}$ werden in Abschnitt 4.2.1 erläutert. Die Ergebnisse basieren auf 10.000 Gibbs-Iterationen, wobei die ersten 2000 nicht berücksichtigt werden. Es wird Priorszenario I angenommen, siehe Tabelle A.2.

und dem Finanzsektor.

Sofern die Volatilitätsreduktion des deutschen BIP-Wachstums auf die Ursachen verbesserte Geldpolitik oder Glück zurückzuführen ist, sollte sich eine starke Volatilitätsreduktion in den Komponenten der Entstehung finden lassen, wie es schließlich im Aggregat der Fall ist. Aus der einfachen Darstellung der unbedingten Standardabweichungen lässt sich bereits schlussfolgern, dass es zumindest noch weitere Einflüsse auf die Volatilität des Aggregats gegeben haben muss als die Einflüsse, die in den Komponenten vorliegen. Um den Einfluss der Komponenten letztlich zu überprüfen, werden die Wachstumsraten der Komponenten auf Strukturbruch untersucht. Die beiden Modelle $\mathcal{M}_{AR,0}$ und $\mathcal{M}_{AR,1}$ werden für die verschiedenen Komponenten der Entstehungsseite und auch der Verwendungsseite angepasst. Die anderen für das BIP-Wachstum zusätzlich herangezogenen Modelle werden an dieser Stelle vernachlässigt, da sie alle einen Strukturbruch in der bedingten Varianz des BIP-Wachstums ermittelt haben und somit zu ähnlichen Ergebnissen führen.

Tabelle 4.6 zeigt die logarithmierten Bayes-Faktoren für die Hypothese eines Varianzbruchs gegen die Hypothese der Strukturkonstanz. Positive Werte bedeuten Evidenz für den Bruch und negative gegen einen Bruch. Auf der Verwendungsseite findet sich mit dem privaten Konsum eine Zeitreihe, die einen positiven Wert aufweist, der allerdings sehr gering ist und im Sinne von Jeffreys' Skala nur als sehr schwache Evidenz für einen Strukturbruch zu werten ist. Die Datierung des Bruchs in der bedingten Varianz des privaten Konsums stimmt mit dem des BIP weitgehend überein,⁴ so dass hier die Volatilitätsreduktion im BIP-Wachstum zumindest zum Teil reflektiert wird. Anders ist die Situation auf der Verwendungsseite. Der einzige Bruch, der Evidenz (sogar sehr starke Evidenz) aufweist, ist in der Landwirtschaft und hat die falsche

⁴Die Datierungen der Brüche der Komponenten werden an dieser Stelle nicht wiedergegeben. Abgesehen vom privaten Konsum (Modus und Mittelwert) gibt es wenige Übereinstimmungen zwischen den Komponenten und dem Aggregat.

Tabelle 4.7: Bayesianische Analyse der kontrafaktischen Zeitreihen

	Log Bayes	Bruchpunktschätzung		
	Faktor	Mittel	Modus	Std. Abw.
festе Anteile (Verwendung)	3.896	1994:I	1993:I	9.478
festе Anteile (Entstehung)	-.082	1996:III	1996:II	15.117

Hinweis: Die logarithmierten Bayes-Faktoren ergeben sich aus $\ln[f(\{y_t\}_{t=1}^T|\mathcal{M}_{AR,1})/f(\{y_t\}_{t=1}^T|\mathcal{M}_{AR,0})]$. Die Modelle $\mathcal{M}_{AR,1}$ und $\mathcal{M}_{AR,0}$ werden in Abschnitt 4.2.1 erläutert. Die Ergebnisse basieren auf 10.000 Gibbs-Iterationen, wobei die ersten 2000 nicht berücksichtigt werden. Es wird Priorszenario I angenommen, siehe Tabelle A.2.


Richtung. Die Volatilitätsreduktion im BIP-Wachstum kann auf keine der Komponenten auf der Entstehungsseite zurückgeführt werden. Glück, eine verbesserte Geldpolitik oder Verbesserungen in der Lagerhaltung scheiden somit im wesentlichen als Ursachen für die Volatilitätsreduktion in Deutschland aus. Dieses Ergebnis steht im Widerspruch zu Buch et al. (2004), die der Geldpolitik und Glück eine Rolle zuordnen, aber auch keine Strukturbruchtests für die Komponenten ausführen.

4.3.2 Strukturwandel

Da die Entwicklung der Volatilität der Komponenten nur wenig insbesondere auf der Entstehungsseite zur Erklärung der Volatilitätsreduktion beitragen kann, sind neben einer Veränderung der Gewichte zwischen hoch volatilen und weniger volatilen Komponenten die Veränderungen der Kovarianzstruktur zwischen den Komponenten mögliche Ursachen reduzierter Volatilität. Beide Aspekte werden in diesem Abschnitt untersucht. Die Frage nach dem Einfluss des Strukturwandels wird analog zu Buch et al. (2004) mit Hilfe einer kontrafaktischen Analyse vorgenommen. Dazu wird eine kontrafaktische Zeitreihe gebildet, die sich aus den Wachstumsraten der einzelnen Komponenten mit festen in der Zeit invarianten Gewichten zusammensetzt. Durch die Fixierung der Gewichte wird der Einfluss des Strukturwandels nivelliert. Für die mit fixen Gewichten aus den Komponenten konstruierte Zeitreihe wird wiederum eine Bayesianische Analyse des AR-Modells auf Strukturbruch in der bedingten Varianz durchgeführt. Es werden also auch hier die Modelle $\mathcal{M}_{AR,0}$ und $\mathcal{M}_{AR,1}$ gegenüber gestellt. Tabelle 4.7 gibt die zugehörigen logarithmierten Bayes-Faktoren und Bruchpunktschätzungen für das Priorszenario I wieder.

Die Bayesianische Analyse wird für zwei kontrafaktische Zeitreihen durchgeführt: zum einen für die Zeitreihe, die mit den Komponenten laut der Entstehungsseite konstruiert wurde, und zum anderen für die Zeitreihe, die auf den Komponenten der Verwendungsseite beruht. Die Gewichte für die Konstruktion entstammen jeweils aus dem Jahr 1971. Für die kontrafaktische Zeitreihe aus den Komponenten der Verwendungsseite findet sich ein ähnlicher Bruch wie für das BIP-Wachstum selbst, für den es mit 3,896 als logarithmierten Bayes-Faktor starke Evidenz

Abbildung 4.2: Anteile der Komponenten der Entstehungsseite am BIP



*produzierende Gewerbe: ◇; Finanzsektor: *; Dienstleistungen: +; Handel und Verkehr: ○; Baugewerbe: ▽; Landwirtschaft: ·.*

Tabelle 4.8: Bayesianische Analyse der paarweisen Korrelationen - Entstehungsseite

	prod. Gewerbe	Baugewerbe	Handel/Verkehr	Finanz	Dienstleistung
unbekannter Bruchpunkt					
Landwirtschaft	0,392	0,245	-2,361	0,720	-0,428
prod. Gewerbe	–	0,457	-0,145	-1,898	0,303
Baugewerbe	–	–	0,203	-0,445	1,636
Handel/Verkehr	–	–	–	-1,396	0,220
Finanz	–	–	–	–	-0,280
fester Bruchpunkt 1993:I					
Landwirtschaft	-0,879	-0,289	-0,030	-0,712	-0,803
prod, Gewerbe	–	-0,070	-1,184	2,424	0,517
Baugewerbe	–	–	1,145	0,745	-0,289
Handel/Verkehr	–	–	–	4,299	-0,200
Finanz	–	–	–	–	-0,983

Hinweis: Die logarithmierten Bayes-Faktoren vergleichen das Modell in den Gleichungen (4.7), (4.8), (4.2) mit einem Bruch ($\rho_0^{ij} \neq \rho_1^{ij}$) mit dem korrespondierenden Modell ohne Bruch ($\rho_0^{ij} = \rho_1^{ij}$). Hervorgehobene Zahlen entsprechen sehr starker Evidenz für einen Bruch nach der Skala von Jeffreys. Die Bayes-Faktoren werden nach der in Anhang A.5 erläuterten Methode berechnet.

gibt. Auf der Verwendungsseite hat die Veränderung der Gewichte also nicht den Einfluss, dass sie den Bruch in der bedingten Varianz hervorruft, da auch ohne die Veränderung der Gewichte ein solcher Bruch gefunden werden kann. Auf der Entstehungsseite sieht das Bild anders aus. Es gibt keine Evidenz für einen Bruch, wenn hier die Gewichte fixiert werden. Der geschätzte Bruchzeitpunkt (Modus) stimmt auch nicht mit dem Modus für den Bruch im BIP-Wachstum überein. Der Strukturwandel in dem Sinne, dass gewisse Sektoren immer bedeutender werden und andere, wie die Landwirtschaft oder die Industrie, an Bedeutung und Gewicht verlieren, hat somit einen großen Einfluss auf die Volatilität des BIP-Wachstums. Ohne diesen Strukturwandel könnte keine Evidenz für einen Bruch gefunden werden.

Abbildung 4.2 zeigt den zeitlichen Verlauf der Gewichte der Komponenten auf der Entstehungsseite. Der Anteil der relativ volatilen Komponente produzierendes Gewerbe nimmt nach der Wiedervereinigung sehr stark ab und die weniger volatilen Komponenten Finanz und Dienstleistung gewinnen an Gewicht. Durch die Wiedervereinigung und den damit verbundenen Abbau der ostdeutschen Industrie sowie die Öffnung nach Osteuropa hat das produzierende Gewerbe an der Bruttowertschöpfung in Deutschland stark an Gewicht verloren. Dieser Umstand trägt unmittelbar auch zur Volatilitätsreduktion des BIP-Wachstums bei. Im Gegensatz zu Buch et al. (2004), die dem Strukturwandel eine untergeordnete Rolle zuschreiben, ist die insbesondere zu Beginn der 90er Jahre intensiviertere Entwicklung von der Industrie- zur Dienstleistungsgesellschaft eine wesentliche Ursache für die Volatilitätsreduktion. Auf der Verwendungsseite findet

Tabelle 4.9: Strukturbruch in paarweisen Korrelationen

	ρ_0		ρ_1		Bruchpunkt	
	Mittel	95%-Band	Mittel	95%-Band	Mittel	95%-Band
fester Bruchpunkt						
prod. Gewerbe & Finanz	0,454	[0,305;0,595]	-0,066	[-0,200;0,062]	1993:I	–
Handel/Verkehr & Finanz	0,524	[0,377;0,661]	-0,092	[-0,220;0,037]	1993:I	–
priv. Konsum & Exporte	0,007	[-0,101;0,115]	-0,319	[-0,552;-0,073]	1993:I	–
Importe & Exporte	0,330	[0,220;0,440]	0,407	[0,203;0,598]	1993:I	–
Geschätzter Bruchpunkt						
Importe & Exporte	0,059	[-0,146;0,369]	0,590	[0,333;0,744]	1985:II	[1980:II;1995:II]

Hinweis: Die Momente der a posteriori Verteilung basieren auf 10.000 Gibbs-Iterationen, wobei die ersten 2000 nicht berücksichtigt werden.

sich die Volatilitätsreduktion des BIP-Wachstums nicht in einer Umgewichtung der Komponenten wieder.

Die reduzierte Volatilität eines Aggregats kann sich in den Komponenten, deren Gewichten und schließlich in der Korrelation widerspiegeln. Abschließend wird also an dieser Stelle die Entwicklung der Korrelation zwischen den Komponenten analysiert. Dabei werden die paarweisen Korrelationen zwischen den Komponenten auf einen Strukturbruch hin im Rahmen einer Bayesianischen Analyse untersucht. Dabei wird das folgende Modell paarweise für die standardisierten Wachstumsraten der Komponenten x_{it}^* und x_{jt}^* unterstellt:

$$\begin{pmatrix} x_{it}^* \\ x_{jt}^* \end{pmatrix} \sim \mathcal{N} \left(\begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 1 & \rho_{dt}^{ij} \\ \rho_{dt}^{ij} & 1 \end{bmatrix} \right), \quad (4.7)$$

mit

$$\rho_{dt}^{ij} = \rho_0^{ij}(1 - d_t) + \rho_1^{ij}d_t, \quad d_t = \begin{cases} 0, & t \leq t^* \\ 1, & t > t^*. \end{cases} \quad (4.8)$$

Die Analyse auf Strukturbruch wird in zwei Varianten durchgeführt. Zum einen wird der Strukturbruch als unbekannt angenommen. Die latente Zustandsvariable d_t folgt dann dem in Gleichung 4.2 beschriebenen Markov-Prozess. Zum anderen wird t^* als bekannt angenommen und auf 1993:I festgelegt. Für das Modell ohne Bruch gilt jeweils $\rho_0^{ij} = \rho_1^{ij}$. Damit der Bruch in der Korrelation die Volatilitätsreduktion im Aggregat erklärt, muss gelten, dass $\rho_0^{ij} > \rho_1^{ij}$. Die Methodik zur Berechnung der Marginalen Likelihoods der Modelle mit Bruch und ohne Bruch wird in Anhang A.5 dargestellt.

Tabelle 4.10: Bayesianische Analyse der paarweisen Korrelationen - Verwendungsseite

	Staatskonsum	Investment	Exporte	Importe
	unbekannter Bruchpunkt			
priv. Konsum	0,882	0,805	-0,349	0,508
Staatskonsum	–	0,841	0,263	0,356
Investment	–	–	-0,930	-0,090
Exporte	–	–	–	3,817
	fester Bruchpunkt 1993:I			
priv, Konsum	-0,366	0,091	3,362	1,263
Staatskonsum	–	-0,732	-0,409	-0,505
Investment	–	–	0,230	-0,690
Exporte	–	–	–	3,250

Hinweis: Die logarithmierten Bayes-Faktoren vergleichen das Modell in den Gleichungen (4.7), (4.8), (4.2) mit einem Bruch ($\rho_0^{ij} \neq \rho_1^{ij}$) mit dem korrespondierenden Modell ohne Bruch ($\rho_0^{ij} = \rho_1^{ij}$). Hervorgehobene Zahlen entsprechen sehr starker Evidenz für einen Bruch nach der Skala von Jeffreys. Die Bayes-Faktoren werden nach der in Anhang A.5 erläuterten Methode berechnet.

Tabelle 4.8 gibt die logarithmierten Bayes-Faktoren für die Komponenten der Entstehungsseite für beide Varianten, mit unbekanntem und mit auf 1993:I festgelegtem Bruch, an. Mit unbekanntem Bruchpunkt gibt es fast kein Paar, für welches der Bruch mehr als nur sehr schwache Evidenz aufweist. Eine Ausnahme bildet das Paar Baugewerbe und Dienstleistungen. Auch um zu überprüfen, ob die in der Analyse mit unbekanntem Bruchpunkt gefundenen Beziehungen zur 1993:I zu verortenden Volatilitätsreduktion beigetragen haben, wird die Variante mit dem festgelegten Bruch untersucht. Das eben genannte Paar Baugewerbe und Dienstleistungen weist keine Evidenz für einen Bruch 1993:I auf. Insbesondere die Paare Handel/Verkehr und Finanz sowie Produzierendes Gewerbe und Finanz bringen Evidenz für einen Bruch in der Korrelation mit sich. Wie in Tabelle 4.9 zu sehen ist, hat die Entwicklung der Korrelation auch das richtige Vorzeichen, so dass ein Teil der Volatilitätsreduktion des BIP-Wachstums der Veränderung der Korrelation zwischen den Sektoren der Entstehungsseite geschuldet ist.

Tabelle 4.10 gibt analog die logarithmierten Bayes-Faktoren für die Komponenten der Verwendungsseite an. Starke Evidenz für einen unbekanntes Bruch findet sich hier nur zwischen den Importen und Exporten. Diese Evidenz bleibt auch bei Fixierung des Bruchs auf 1993:I erhalten. Hinzukommt bei bekanntem Bruch auch das Paar Privater Konsum und Exporte. Wie in Tabelle 4.9 ersichtlich führt der Bruch in der Korrelation zwischen Privatem Konsum und Exporten zu einer Reduktion der Korrelation, die dadurch negativ wird. Auf der Verwendungsseite ist die Volatilitätsreduktion somit zum Teil in der Korrelation zwischen privatem Konsum und Exporten zu finden. Der Bruch der Korrelation zwischen Exporten und Importen bietet hingegen keine Erklärung für eine Volatilitätsreduktion, da durch den Bruch die Korrelation

gestiegen ist. Die Bayesianische Schätzung des Bruchs ergibt einen Mittelwert der a posteriori Verteilung des Bruchs von 1985:II bei einem relativ breiten 95% Band von 15 Jahren. Der Anstieg der Korrelation zwischen Exporten und Importen deutet auf die wachsende internationale Verflechtung der deutschen Ökonomie hin, welche bereits vor der Wiedervereinigung einsetzte.

Abschließend sind aus der Analyse der Komponenten folgende Schlüsse für die Ursachen der Volatilitätsreduktion des BIP-Wachstums in Deutschland zu ziehen: Da in den einzelnen Komponenten auf der Entstehungsseite keine Evidenz für einen Bruch gefunden werden konnte und die Unterschiede in der Standardabweichung vor und nach 1993 zum Beispiel im produzierenden Gewerbe bedeutend geringer sind als im Aggregat, sind eine verbesserte Geldpolitik und Glück als Ursachen von untergeordneter Bedeutung. Die Folgen dieser Ursachen sollten zumindest in einzelnen Komponenten feststellbar sein. Vielmehr spielt der Rückgang des Industriesektors, der auf Gesamtdeutschland bezogen wegen der Abwicklung ostdeutscher Betriebe in der ersten Hälfte der 90er Jahre besondere Dynamik hatte, eine große Rolle. Ohne diese Entwicklung wäre keine Evidenz für einen Strukturbruch in der bedingten Varianz vorhanden. Schließlich wird diese Entwicklung von einigen Veränderungen in der Kovarianz zwischen den Komponenten begleitet. Ob diese ebenfalls Folge des Strukturwandels sind oder auf Innovationen im Bereich der Finanzintermediation bzw. in anderen Bereichen zurückzuführen sind, kann an dieser Stelle nicht geklärt werden.

Auf der Verwendungsseite kann die Volatilitätsreduktion im BIP-Wachstum auch mit einer Volatilitätsreduktion im privaten Konsum in Verbindung gebracht werden, jedoch ist auch diese zu geringfügig um das ganze Geschehen aufzufangen. Vielmehr scheint auf der Verwendungsseite die Korrelation zwischen den Komponenten ebenfalls eine Veränderung erlebt zu haben. Insbesondere die Korrelation zwischen Exporten und privatem Konsum ist hier zu nennen.

4.4 Schluss

Die hier vorliegende Analyse kann das Ergebnis von Buch et al. (2004) bestätigen, dass das deutsche BIP-Wachstum eine starke Reduktion der bedingten Varianz in den 90er Jahren erlebt hat. Alternativ zu Buch et al. (2004) werden hier Bayesianische Verfahren verwendet, die eine bessere Möglichkeit zur Datierung des Bruchs über die Bestimmung seiner a posteriori Verteilung bieten. Zusätzlich wird die Analyse der bedingten Fehlervarianz für verschiedene Mittelwertgleichungen durchgeführt. Die Analyse autoregressiver Modelle und von Markov-Switching-Modellen (im Interzept) kommen zu ähnlichen Ergebnissen im Bezug auf Evidenz, Datierung und Charakterisierung des Bruchs. Die Volatilitätsreduktion lässt sich aus Sicht dieser Modelle am besten als Reduktion der bedingten Varianz im ersten Quartal 1993 darstellen. Alternative Ansätze, die eine veränderte Dynamik vorschlagen (Fritsche und Kuzin [2005a]) oder eine geringere Amplitude zwischen Konjunkturphasen vermuten, werden nicht bestätigt.

Das DLR-Modell, welches als drittes Mittelwertmodell berücksichtigt wird, liefert eine andere Charakterisierung der Volatilitätsreduktion. Zwar gibt es auch hier Evidenz für einen Bruch in der bedingten Varianz, dieser wird jedoch später auf 1999 datiert. Die bereits seit 1993 geringere Volatilität wird im DLR-Modell durch ein entsprechendes Mittelwertregime abgebildet, welches zusammen mit dem Bruch in der Fehlervarianz des DLR-Modells in 1999 endet.

An die Datierung und Charakterisierung der Volatilitätsreduktion des deutschen BIP-Wachstums schließt sich die Frage nach den Ursachen an. Die hier vorliegende Arbeit fokussiert die Analyse dabei auf die Komponenten der Entstehungsseite des BIP. Die Strukturbruchanalyse der Wachstumsraten der einzelnen Komponenten über den Vergleich der Modelle $\mathcal{M}_{AR,0}$ und $\mathcal{M}_{AR,1}$ zeigt, dass Verbesserungen der Geldpolitik oder Glück als wesentliche Ursachen ausscheiden. Die kontrafaktische Analyse einer aus den Komponenten konstruierten Zeitreihe zeigt die Bedeutung des Strukturwandels in Form des relativen Rückgangs des produzierenden Gewerbes auf. Hier ist eine der Hauptursachen der Volatilitätsreduktion in Deutschland zu sehen. Ferner hat sich die Korrelationsstruktur zwischen den Komponenten verändert, so dass diese weniger Volatilität implizieren. Auf der Verwendungsseite lässt sich die Volatilitätsreduktion ebenfalls nur zu einem geringen Teil in der Volatilität der einzelnen Komponenten verfolgen, hier am meisten im Privaten Konsum. Von Bedeutung ist auf der Entstehungsseite jedoch nicht eine Gewichtsverschiebung zwischen den Komponenten, sondern die Veränderung der Korrelationsstruktur, insbesondere ist die Korrelation zwischen Exporten und Privatem Konsum nach dem Bruch in 1993:I negativ geworden.

Kapitel 5

Zeitvariierende Vorlaufeigenschaften von Frühindikatoren

5.1 Frühindikatoren in der Konjunkturforschung

5.1.1 Was ist ein Frühindikator?

Die monatlichen Veröffentlichungen des Ifo- sowie des ZEW-Index stoßen regelmäßig auf ein großes öffentliches Interesse. Beide Variablen gelten als Frühindikatoren der deutschen Konjunktur. Die wesentliche Eigenschaft von Frühindikatoren ist, dass sie mit zukünftigen Werten der Konjunkturvariable oder gleichlaufender Indizes korrelieren. Spätestens seit der Arbeit von Burns und Mitchell (1946), die die zeitliche Korrelationsstruktur verschiedener makroökonomischer Variablen analysiert haben, wird diesem Thema großes Interesse von Seiten der Politik, Wirtschaft und Medien entgegengebracht in der Hoffnung verlässliche Signale bzw. Prognosen für die zukünftige wirtschaftliche Entwicklung zu erhalten als zum Beispiel von ökonomischen Modellen oder univariaten Zeitreihenmodellen.¹

Bei der Betrachtung und Begutachtung von Frühindikatoren ist einer der ersten Fragen, welche Variable die Zielvariable ist bzw. welcher Konjunkturvariable sie vorlaufen. Zwei Konjunkturvariablen sind Gegenstand dieser Arbeit in den vorangegangenen Kapiteln, das BIP bzw. sein Wachstum sowie die diskrete Variable, die den Zeitverlauf in Expansionen und Rezessionen einteilt. Wie bereits erwähnt, kann das BIP als der umfassendste Konjunkturindikator gelten und spielt daher als Zielvariable von Frühindikatoren eine große Rolle. Das BIP und somit auch seine Wachstumsraten oder gefilterte Derivate wie der Output-Gap haben in der Regel den Nachteil nur quartalsweise vorzuliegen. Als Zielvariable einer höheren Frequenz dient oft die Industrieproduktion, die monatlich erhoben wird. Ihr Nachteil wiederum ist, dass sie (nur) einen immer

¹Vgl. Abschnitt 2.6.

kleiner werdenden Anteil der Ökonomie abbildet.² Alternativ haben Stock und Watson (1989) ein Dynamisches Faktormodell vorgeschlagen, dass aus mehreren monatlich verfügbaren (gleichlaufenden) Indikatoren einen dahinter liegenden Faktor extrahiert. Der Ansatz, einen Faktor bzw. mehrere Faktoren aus einer großen Datenmenge zu extrahieren, um so einen gleichlaufenden Indikator zu gewinnen wird in Forni et al. (2001) sowie Altissimo et al. (2006) für die ökonomische Aktivität der Eurozone verfolgt. Ferner ist das Dynamische Faktormodell von Stock und Watson (1989) unter Berücksichtigung gemischt frequenter Daten erweitert worden, so dass monatliche Repräsentationen des BIP möglich sind, siehe Mariano und Murasawa (2003), Nunes (2005) oder Proietti und Moauro (2006).

Als Frühindikatoren werden Variablen aus verschiedenen Bereichen der Ökonomie angesehen. Burns und Mitchell (1946) diskutieren 487 und Stock und Watson (1989) 280 mögliche Zeitreihen für die USA. Manche Frühindikatoren bilden explizit oder implizit Erwartungen über zukünftiges wirtschaftliches Geschehen ab; dies ist explizit der Fall für umfragebasierte Indizes wie den Ifo-Indizes und dem ZEW-Index oder implizit in Zinsdifferenzen und Aktienpreisen. Andere Frühindikatoren haben einen direkten Zusammenhang zum zukünftigen wirtschaftlichen Geschehen einzelner Sektoren, wie der Auftragseingang im verarbeitenden Gewerbe oder Baugenehmigungen. Andere Variablen wie z.B. Kfz-Zulassungszahlen können als Proxy für Investitionen und folgende ökonomische Aktivität gelten. Wenn die Frühindikatoren aus verschiedenen Sektoren entstammen, wie z.B. Anzahl der Baugenehmigungen oder Auftragseingang der Industrie, also nicht die Erwartungen über die Gesamtlage abbilden oder offensichtlich idiosynkratischen Einflüssen unterliegen, erscheint es sinnvoll die Informationen mehrerer Variablen zusammenzubringen und sich nicht auf einen einzelnen Frühindikator zu verlassen. Auch wenn man von Frühindikatoren, wie die Zinsdifferenz, von denen angenommen wird, dass sie allgemeine wirtschaftliche Erwartungen in sich enthalten, ausgeht, kann eine Verwendung mehrerer Indikatoren in zusammengesetzter Form sinnvoll sein. In Abschnitt 5.2 wird diskutiert, dass auch diese Frühindikatoren erheblichen Veränderungen im Vorlaufverhalten unterliegen können. Zusammengesetzte Frühindikatoren werden zum Beispiel von der OECD (als Zielvariable dienen dort die Wechsellpunkte der Konjunktur) oder vom Conference Board, einem Unternehmerverband mit Sitz in den USA, erstellt. Die Gewichtung, mit der die einzelnen Variablen in den zusammengesetzten Frühindikator einfließen, unterliegt in diesen beiden Fällen Expertenurteilen. Alternativ gibt es zusammengesetzte Frühindikatoren, deren Gewichtungen auf Faktormodellen basieren, siehe Stock und Watson (1989) oder Forni et al. (2001).

Als wesentlicher und wohl bedeutenster Aspekt zur Beurteilung der Güte eines Frühindikators dient die Prognosegüte im Bezug auf die Zielvariable. Dies ist jedoch nicht der einzige Aspekt. Moore und Shiskin (1967) diskutieren weitere Kriterien, die ebenfalls von Marcellino (2006) aufgenommen und im Folgenden kurz erläutert werden:

²Der Einfluss der anteilmäßigen Veränderung des Industriesektors auf die Gesamtökonomie wird unter anderem in Kapitel 4 besprochen.

1. **Konsistente Datierung von Expansionen und Rezessionen**, wobei der dem jeweiligen Frühindikatoren korrespondierende Vorlauf zur Zielvariablen zu berücksichtigen ist. Wenn die Zielvariable die diskrete Regimevariable selber ist, entspricht dieses Kriterium der Forderung nach guten Prognosen für die Regimewechsel.
2. **Ökonomische Bedeutung**. Der Frühindikator bzw. seine Vorlaufeigenschaften sollten durch ökonomische Theorien begründbar sein. Frühindikatoren, die diesen Status nur wegen ihrer statistischen Eigenschaften zugesprochen bekommen, setzen sich der bereits von Koopmans (1947) geäußerten Kritik “measurement without theory” aus.
3. **Verlässlichkeit der Datenerhebung**. Der berichtete Frühindikator soll dem entsprechen, was gemessen werden soll, und dies konsistent über den Zeitverlauf hinweg. Dieses Kriterium ist z.B. von Bedeutung, wenn man an die umfragebasierten Erhebungen wie Ifo- oder ZEW-Index denkt und es dabei zu methodischen Veränderungen der Befragungen kommen kann.
4. **Zeitnahe Zugänglichkeit und Revisionsfreiheit**. Analog zum in Kapitel 6 diskutierten Problem für das BIP gilt auch für Frühindikatoren, dass es wünschenswert ist sie zeitnah und mit geringen Messfehlern behaftet beobachten zu können.
5. **“Sanfte” monatliche Übergänge**. Der Frühindikator soll die Konjunktorentwicklung abbilden und möglichst nicht von idiosynkratischen hochfrequenten Bewegungen überlagert sein.

Die Punkte 3 und 4 machen die Verwendung von Finanzmarktindikatoren wie Zinssätze oder Aktienindizes sehr attraktiv, da sie quasi in beliebiger Frequenz und sofort bei Entstehung verfügbar und keinerlei Revisionen unterworfen sind. Dies erklärt auch zum Teil die große Aufmerksamkeit, die der Zinsdifferenz als Frühindikator entgegengebracht wird, und in späteren Abschnitten dieses Kapitels von Bedeutung sein wird. Marcellino (2006) verbindet mit Punkt 2 das Problem, dass Korrelationen zwischen Frühindikator und Zielvariable nur zufällig sein können. Eine theoretisch begründbare Verbindung verspricht in diesem Sinne Stabilität, da die statistische Korrelation auf Verhaltensmuster der ökonomischen Agenten zurückzuführen ist. Hierbei ist jedoch zu bedenken, dass es keine generell anerkannte und umfassende Konjunkturtheorie gibt.³ Die Begründungen für konjunkturelle Schwankungen sind vielfältig und zum Teil kontrovers. In weiten Teilen wird die Auffassung vertreten, dass verschiedene Ursachen zu einer Rezession bzw. zu konjunkturellen Schwankungen führen können und die Gewichtung dieser Ursachen in der Zeit variiert.⁴

³Siehe z.B. die Darstellung der Ergebnisse der Konferenz “Beyond Shocks: What Causes Business Cycles?” von Fuhrer und Schuh (1998).

⁴Vgl. Stock und Watson (2003a) oder Marcellino (2006).

Die Abschnitte 5.2 und 5.3 werden explizit für die Zinsdifferenz auf den Zusammenhang ökonomischer Signifikanz und Instabilität der Vorlaufeigenschaften eingehen und die Relevanz scheinbarer ökonomischer Signifikanz kritisch hinterfragen. Dabei steht die empirische Analyse der Vorlaufeigenschaften der Zinsdifferenz für die USA und Deutschland sowie deren möglicher Zusammenhang mit der Geldpolitik im Mittelpunkt. Exemplarisch wird anhand der Zinsdifferenz aufgezeigt, dass Vorlaufeigenschaften von Frühindikatoren zum Teil erheblichen Schwankungen unterliegen und dass einfache ökonomische Theorien, die ein Vorlaufverhalten erklären können, keine Garantie gegen Instabilitäten und eventuelle Ausfälle der korrespondierenden Frühindikatoren bieten. Im Mittelpunkt steht dabei die durch das Modell von Estrella (2005) motivierte Hypothese, dass Schwankungen im Vorlaufverhalten der Zinsdifferenz durch Veränderungen in der Geldpolitik induziert werden. Diese Hypothese wird mit Hilfe eines gemeinsamen Markov-Switching-Modells für das Vorlaufverhalten und die Geldpolitik in Form einer an die Taylor-Regel angelehnten Gleichung überprüft, siehe Abschnitt 5.3. Im folgenden Abschnitt 5.1.2 werden zunächst verschiedene Modelle vorgestellt, die in der Literatur verwendet werden, um Frühindikatoren für Vorhersagen nutzbar zu machen.

5.1.2 Frühindikatoren und Vorhersagemodelle

Der Sinn von Frühindikatoren besteht darin Prognosen für die Zielvariable bereitzustellen. Um aus den Frühindikatoren Prognosen zu gewinnen, wird in der Regel über ein Modell ein Zusammenhang zwischen Frühindikator und Zielvariable hergestellt. Im Folgenden werden gängige Frühindikatormodelle dargestellt.

Lineare Modelle

Sofern die Zielvariable metrisch ist, besteht eine einfache Variante in Form eines linearen Modells, das eine oder mehrere vorlaufende Variablen als Regressoren und die Zielvariable als Regressand hat. Das lineare Modell kann im Fall mehrerer Regressoren als zusammengesetzter Frühindikator interpretiert werden. Insbesondere in der Diskussion einzelner Frühindikatoren findet dieses Modell Anwendung.⁵ Das einfache lineare Regressionsmodell hat den Nachteil, dass für jeden Prognosehorizont eine neue Schätzung durchgeführt werden muss, da bei der Ausweitung des Prognosehorizonts die Frühindikatoren nicht weiter fortgeschrieben werden können.⁶ Alternativ werden in VAR-Modellen die Interaktionen zwischen den Frühindikatoren untereinander sowie

⁵Vgl. Abschnitt 5.2.

⁶Johnston (1974) weist daraufhin, dass sofern das Modell richtig spezifiziert ist, iterative Fortschreibungen des Modells, wie sie im VAR möglich sind, effizientere Vorhersagen ermöglichen als direkte Mehr-Schritt-Prognosen. Siehe Marcellino et al. (2006) für eine empirische Analyse zum Vergleich von iterierten und direkten Mehr-Schritt-Prognosen.

der Zielvariablen berücksichtigt, so dass das ganze System fortgeschrieben werden kann.⁷

Faktormodelle

Sofern eine Vielzahl von Variablen im Vorhersagemodell berücksichtigt werden soll, ergeben sich im VAR-Modell Probleme durch die große Anzahl an Parametern des Modells. Ferner fällt auch im einfachen linearen Regressionsmodell der Aspekt der Multikollinearität ins Gewicht. Naturgemäß weisen Frühindikatoren oft hohe Korrelationen untereinander auf. Genau dieser Umstand wird im Rahmen von Faktormodellen ausgenutzt. Die Idee ist, dass die Korrelation zwischen einer Vielzahl von Variablen darauf beruht, dass diese von einer geringeren Zahl unbeobachtbarer Faktoren getrieben werden. Faktormodelle sind seit vielen Jahrzehnten in der Analyse von Querschnittsdaten etabliert, wo angenommen werden kann, dass keine Abhängigkeit zwischen den Merkmalsträgern herrscht, siehe zum Beispiel Spearman (1904) oder Thurstone (1947). Übertragen auf den Zeitreihenkontext hieße dies die Freiheit von jeder Form der Autokorrelation. Für die n Variablen mit T Beobachtungen, die in der Matrix X zusammengefasst sind, ergibt sich dann folgendes Modell:

$$X = F\Lambda' + U, \quad (5.1)$$

wobei die $T \times q$ Matrix F die unbeobachtbaren Faktoren repräsentiert und die $n \times q$ Matrix Λ die Faktorladungen. U sind die idiosynkratischen Komponenten, die weder über die Zeit noch zwischen den Variablen korrelieren. Es ist schließlich die Idee, dass die Korrelation zwischen den Variablen durch die Faktoren abgebildet wird. Die Faktoren und Ladungen können mit Hilfe einer Hauptkomponentenanalyse geschätzt werden. Wenn die Varianzen der idiosynkratischen Komponenten identisch sind ($\Sigma_U = \sigma_U^2 I$), dann entspricht das Ergebnis der Hauptkomponentenanalyse der ML-Schätzung. Das Ergebnis ist jedoch in keinem Fall eindeutig. Die Faktorladungen können entsprechend rotiert werden.

Für makroökonomische Größen erscheint die Annahme, dass keine Autokorrelation existiert, zu restriktiv. Die Arbeiten von Sargent und Sims (1977) sowie Geweke (1977) berücksichtigen eben diesen Punkt und führen Dynamische Faktormodelle ein, die eine zusätzliche autoregressive Struktur der Faktoren aufnehmen und eine explizite Berücksichtigung autoregressiver idiosynkratischer Strukturen ermöglichen:

$$F_t = \sum_{i=1}^k \Phi_i F_{t-i} + V. \quad (5.2)$$

Sargent und Sims (1977) sowie Geweke (1977) schätzen das Dynamische Faktormodell im Frequenzbereich mit der Maximum-Likelihood-Methode. Eine Maximum-Likelihood-Schätzung des Dynamischen Faktormodells in der Zeitdarstellung findet sich in Watson und Engle (1983).

⁷VAR-Modelle werden für deutsche Daten zum Beispiel von Breitung und Jagodzinski (2002), Benner und Meier (2004), Fritsche und Stephan (2002) oder Hüfner und Schröder (2002) verwendet.

Die Likelihood kann mit Hilfe des Kalman-Filters berechnet und numerisch maximiert werden. Alternativ kann die Maximum-Likelihood-Schätzung mit Hilfe des Kalman-Glätters über den EM-Algorithmus, wie auch in Watson und Engle (1983), durchgeführt werden. Analog zum (statischen) Faktormodell existiert auch im Dynamischen Faktormodell das Identifikationsproblem, das durch entsprechende Parameterrestriktionen berücksichtigt werden kann, siehe dazu z.B. Geweke (1977) oder Geweke und Singleton (1981). Stock und Watson (1989,1991) verwenden das Dynamische Faktormodell mit einem Faktor zur Bestimmung eines gleichlaufenden Konjunkturfaktors. Basierend auf diesem Konjunkturfaktor erweitern sie das Modell, um einen zusammengesetzten Frühindikator zu gewinnen. Bandholz und Funke (2003) verwenden ein Dynamisches Faktormodell um aus Auftragseingängen und Lagerbeständen einen zusammengesetzten Frühindikator für die deutsche Konjunktur zu gewinnen. Zielvariable ist dabei das BIP-Wachstum.

Wenn die Anzahl der zu berücksichtigenden Variablen im Dynamischen Faktormodell sehr groß ist, ist die Maximum-Likelihood-Schätzung rechenintensiv und zeitaufwendig. Mit Hilfe Bayesischer Methoden können auch höhere parametrisierte Modelle mit vertretbarem Zeitaufwand geschätzt werden, siehe Otrok und Whiteman (1998) sowie Kose et al. (2003).⁸

Alternativ findet die im Zusammenhang mit Faktormodellen für Querschnittsdaten eingeführte Hauptkomponentenanalyse Anwendung im Zeitreihenkontext.⁹ Bai (2003) hat gezeigt, dass die strikten Annahmen des klassischen Faktormodells teilweise aufgehoben werden können und die Hauptkomponentenanalyse konsistente und asymptotisch normalverteilte Schätzer erbringt, sofern die Anzahl der Variablen gegen unendlich strebt. Was also für die Maximum-Likelihood-Schätzung eines (exakten) dynamischen Faktormodells problematisch ist, ist Voraussetzung für das sogenannte approximative Faktormodell. Bei approximativen Faktormodellen ist zu berücksichtigen, dass die durch die Hauptkomponentenanalyse ermittelten "statischen" Faktoren zwar zeitgleich orthogonal zueinander sind, deren Zeitverzögerte aber miteinander korrelieren und im Extrem ein oder mehrere "statische" Faktoren Linearkombinationen der zeitverzögerten anderen Faktoren sind, also die Anzahl der dynamischen Faktoren geringer ist als die der "statischen" Faktoren.¹⁰ Dieser Umstand ist insbesondere bei der Interpretation der Ergebnisse der Faktormodelle zu berücksichtigen.

Markov-Switching Modelle

Seit Hamilton (1989) finden Markov-Switching-Modelle Verwendung zur Darstellung makroökonomischer Zeitreihen, vgl. Abschnitt 2.1.2. Frühindikatoren lassen sich in verschiedener Weise mit diesem Modelltyp verbinden. Hamilton und Perez-Quiros (1996) schlagen eine Erweiterung des

⁸Siehe auch Kim und Nelson (1999b).

⁹Siehe unter anderem Chamberlain und Rothschild (1983) oder Stock und Watson (2002b).

¹⁰Siehe zum Verhältnis zwischen statischen und dynamischen Faktoren Amengual und Watson (2007) oder Bai und Ng (2007).

VAR-Modells vor, wobei eine gemeinsame Zustandsvariable unterstellt wird, die den Mittelwert der Zielvariable und des Frühindikators beeinflusst. Die Zustandsvariable folgt einem Markov-Prozess. Der Vorlaufcharakter des Frühindikators wird dadurch berücksichtigt, dass sich der Mittelwert des Frühindikators nach der gleichzeitigen Ausprägung der Zustandsvariablen richtet, während der Mittelwert der Zielvariable sich nach der verzögerten Zustandsvariablen richtet. Die Idee ist, dass die Zustandsänderungen erst beim Frühindikator beobachtbar werden und dies dann die Zustandsveränderung der Zielvariable nach sich zieht.

Ferner wendet Chauvet (1998) ein Dynamisches (Ein-)Faktormodell an, bei dem der unbeobachtbare Faktor von einem Markov-Prozess abhängt. Bandholz und Funke (2003) wenden ein solches Modell für deutsche Daten an.¹¹ Alternativ geht Filardo (1994) vom univariaten Hamilton-Modell aus und modifiziert die Übergangswahrscheinlichkeiten. Frühindikatoren dienen als Argumente in logistischen Funktionen, welche die Übergangswahrscheinlichkeiten bilden, so dass diese in der Zeit mit den Frühindikatoren variieren.

Im Zusammenhang mit Markov-Switching-Modellen werden häufig auch Schwellenwertmodelle oder Übergangsmo-
delle diskutiert, die ähnlich Markov-Switching-Modellen eine Zustandsabhängigkeit der Modellparameter konstituieren, vgl. Abschnitt 2.1.4. Analog zum Modell von Filardo (1994) werden Frühindikatoren auch hier genutzt um die Zustandswechsel bzw. -übergänge zu modellieren, siehe zum Beispiel Granger et al. (1993) oder Camacho (2004).

Binäre Modelle

Neben metrischen Daten wie dem BIP-Wachstum oder der Industrieproduktion werden auch binäre Variablen als Zielvariablen verwendet, so lässt sich aus den bereits in Kapitel 3 diskutierten Wechsellagen der Konjunktur eine binäre Variable konstruieren, die den Wert 1 in Rezessionen annimmt. Zur Vorhersage von Rezessionen können dann Logit oder Probit-Modelle herangezogen werden, in denen die Frühindikatoren als Regressoren aufgenommen werden können.¹² Alternativ werden zur Rezessionsvorhersage die bereits besprochenen Markov-Switching-Modelle verwendet, wobei die unbeobachtbare Zustandsvariable als binärer Konjunkturindikator interpretiert wird.¹³ Eine Erweiterung des Probit-Modells findet sich in Dueker (2005). Das dort beschriebene Qual-VAR ermöglicht es die Korrelation der binären Variable mit anderen Variablen zeitgleich zu berücksichtigen und eignet sich ferner zur Fortschreibung der Daten. Qual-VAR oder Qualitative-Vector-Autoregressive-Modell steht für ein VAR-Modell, in dem mindestens eine der abhängigen Variablen diskret bzw. qualitativ ist. Das eigentliche VAR-Modell besteht dabei aus den metrischen und den latenten Variablen.

¹¹Für die ML-Schätzung eines Dynamischen Faktormodells mit Markov-Switching wird von den Autoren die Approximation von Kim (1994) verwendet, da eine exakte Berechnung der Likelihood zu rechenintensiv ist.

¹²Für Beispiele siehe Stock und Watson (1991), Birchenhall et al. (1999) oder Birchenhall et al. (2001).

¹³Fritsche und Kuzin (2005b) verwenden beide Ansätze für deutsche Daten.

5.2 Die Zinsdifferenz als Frühindikator der Konjunktur

Am Beispiel der Zinsdifferenz wird im Folgenden ein mögliches Problem von Frühindikatoren diskutiert, dass deren Vorlaufeigenschaften nicht stabil über die Zeit sind. Es soll ein möglicher Bestimmungsgrund der Instabilität der Vorlaufeigenschaften der Zinsdifferenz diskutiert werden. Im Mittelpunkt steht dabei angelehnt an das Modell von Estrella (2005), das einen Zusammenhang zwischen den Vorlaufeigenschaften der Zinsdifferenz und der Reaktionsfunktion der Geldpolitik aufzeigt, die Frage, ob die Instabilität der Vorlaufeigenschaften durch Veränderungen der Geldpolitik induziert wird. Für Deutschland und die USA wird die auf dem Modell von Estrella (2005) basierende Hypothese überprüft, dass zeitliche Schwankungen der Vorlaufeigenschaften der Zinsdifferenz mit geldpolitischen Schwankungen korrespondieren.

5.2.1 Lineares Vorhersagemodell

Bezüglich der Zinsdifferenz gibt es keine Probleme der zeitlichen Nähe zwischen Entstehung und Beobachtung, ferner unterliegen sie keinen Revisionen. Außerdem existieren Ansätze die Vorlaufeigenschaften der Zinsdifferenz aus der ökonomischen Theorie herzuleiten.¹⁴ Wie bereits erwähnt, ist die Zinsstrukturkurve bzw. die Zinsdifferenz aus diesen Gründen ein wünschenswerter Frühindikator. In vielen Arbeiten wird Evidenz für die Zinsdifferenz als Frühindikator der Konjunktur gefunden.¹⁵ Grundlegend ist dabei das folgende einfache lineare Modell:

$$y_t^k = \alpha + \beta S_t + \varepsilon_t, \quad \varepsilon_t \stackrel{i.i.d.}{\sim} (0, \sigma^2), \quad (5.3)$$

wobei y_t^k die Differenz der logarithmierten Werte des BIP der Zeitpunkte t und $t + k$ ist. In vielen Arbeiten werden anstelle des BIP die Industrieproduktion oder ähnliche real-ökonomische Indikatoren verwendet.¹⁶ k repräsentiert an dieser Stelle den Vorhersagehorizont. S_t gibt die Zinsdifferenz zweier risikofreier Papiere unterschiedlicher Maturität wieder. Typischerweise wird die Differenz zwischen Papieren der Maturitäten von drei Monaten und 10 Jahren gebildet. Die Zinsdifferenz zeigt in vielen Ländern für verschiedenen Zeiträume und Vorhersagehorizonte gute Vorlaufeigenschaften nicht nur für die USA, sondern auch für kleinere Ökonomien wie Belgien oder die Niederlande.¹⁷

5.2.2 Nicht-Linearität und Instabilität der Vorlaufeigenschaften

Mehrere Arbeiten weisen darauf hin, dass die Zinsdifferenz ein über die Zeit variierendes Vorlaufverhalten aufweist bzw. dass Nicht-Linearitäten im Verhältnis zwischen zukünftiger real-öko-

¹⁴Vgl. Abschnitt 5.2.3.

¹⁵Siehe unter anderen Plosser und Rouwenhorst (1994), Estrella und Mishkin (1997) oder Dotsey (1998).

¹⁶Ferner wird die Zinsdifferenz im Rahmen von Probit-Regressionen zur Rezessionsvorhersage verwendet, siehe unter anderem Estrella und Hadrouvelis (1991), Dueker (1997), Estrella und Trubin (2006) oder Wright (2006).

¹⁷Siehe Bernard und Gerlach (1998).

nomischer Aktivität und der Zinsdifferenz existieren. Bereits Haubrich und Dombrosky (1996) argumentieren, dass die Prognosegüte der Zinsdifferenz für das reale BIP-Wachstum der USA für die Jahre 1985 bis 1995 niedriger war als in den Jahren zuvor. Die Güte des linearen Prognosemodells in verschiedenen Zeitfenstern wird ferner von Giacomini und Rossi (2006) für die USA und darüber hinaus für das UK und Deutschland von Schrimpf und Wang (2007) diskutiert.

Estrella et al. (2003) finden für die USA, dass ein Strukturbruch im Vorlaufverhalten zwischen Zinsdifferenz und Industrieproduktion stattgefunden hat, der zu einer Verschlechterung der Prognosegüte führt. Chauvet und Potter (2002) deuten im Gegensatz zu Estrella et al. (2003) daraufhin, dass es einen Bruch auch für die Rezessionsprognose gegeben hat, der jedoch nicht zur Verschlechterung der Prognoseeigenschaften geführt hat. Schließlich deuten Venetis et al. (2003) daraufhin, dass die Prognosegüte der Zinsdifferenz in den USA, dem UK und Kanada jeweils nach einem Strukturbruch für Prognosehorizonte über 4 Quartale dramatisch sinkt. In der Arbeit von Venetis et al. (2003) wird zusätzlich für Schwelleneffekte kontrolliert. Galbraight und Tkacz (2000) führen die Berücksichtigung von Schwelleneffekten in die Literatur der Prognosen mit Zinsdifferenzen ein und finden diese im Vorlaufverhalten für die USA und Kanada. Als Schwellenvariable verwenden Galbraight und Tkacz (2000) die Zinsdifferenz. Unter Verwendung anderer Schwellenvariablen und eines Smooth-Transition-Modells finden Venetis et al. (2003) Schwelleneffekte auch für das UK.

In vielen Ländern findet sich eine Zeitvariation der Prognosegüte der Zinsdifferenz. Die Tatsache, dass Vorlaufeigenschaften der Zinsdifferenz existieren, macht die Frage nach den Gründen dafür und den dahinter liegenden Zusammenhängen nicht nur aus theoretischer Sicht interessant. Die Zeitvariation des Vorlaufverhaltens impliziert, dass diese Fragestellung auch für den Vorhersager von Interesse ist. Die Kenntnis über die Ursachen des Vorlaufverhaltens ermöglicht eventuell Inferenz über die Frage, wann und wie sehr der Zinsdifferenz als Frühindikator Beachtung geschenkt werden muss. Außerdem würde eine Erklärung des zeitvariierenden Verhaltens des Vorlaufverhaltens der Zinsdifferenz die ökonomische Bedeutung dieses Frühindikators stärken bzw. wiederherstellen.

5.2.3 Warum ist die Zinsdifferenz ein Frühindikator?

Eine ad hoc Erklärung dafür, dass die Zinsdifferenz ein Frühindikator ist, liefert die Annahme, dass Zentralbanken antizyklische Geldpolitik betreiben. Laut der Erwartungshypothese bildet die Zinsdifferenz die erwartete Zinsänderung ab. Wenn ein konjunktureller Abschwung bevorsteht, wird die antizyklisch agierende Zentralbank ihre Zinsen senken, so dass sich die Zinsdifferenz schon im voraus verringern oder umkehren wird.¹⁸ Die Zinsdifferenz gilt hier folglich im Zusammenhang mit der Geldpolitik als Frühindikator.

Plosser und Rouwenhorst (1994) argumentieren, dass die Vorlaufeigenschaften der Zinsdif-

¹⁸Vgl. zum Beispiel Estrella und Hadrouvelis (1991).

ferenz im Rahmen von Real-Business-Cycle-Modellen als Erwartungen über Produktivitätsschocks aufgefasst werden können, die entsprechenden Einfluss auf das zukünftige Zinsniveau haben. Schließlich lassen sich die Vorlaufeigenschaften der Zinsdifferenz auch im Rahmen des Consumption-based-asset-pricing-Modells interpretieren, indem ein Zusammenhang zwischen zukünftigem Konsum und zukünftigen Renditen besteht, vgl. Harvey (1988).

Estrella (2005) systematisiert den Zusammenhang zwischen Geldpolitik und Vorlaufeigenschaften der Zinsdifferenz. Im Folgenden werden Auszüge aus dem Modell von Estrella (2005) eingeführt, die die Vorlaufeigenschaften der Zinsdifferenz im Bezug auf real-ökonomisches Geschehen konstituieren:

- Die Inflationsdynamik wird durch die Phillips-Kurve abgebildet:

$$\pi_t = \pi_{t-1} + ax_{t-1} + \epsilon_t^\pi,$$

wobei π_t die Inflationsrate und x_{t-1} den verzögerten Output-Gap darstellen. Zusätzlich wird ein Fehlerterm ϵ_t^π berücksichtigt.

- Die Geldpolitik wird durch die folgende Reaktionsfunktion abgebildet:

$$i_t = g_i i_{t-1} + g_\pi \pi_t + g_x x_t + (1 - g_r - g_\pi) \pi^*,$$

wobei i_t der (kurzfristige) Zinssatz über eine Periode ist und π^* die gewünschte Inflationsrate angibt. Es wird angenommen, dass die Zentralbank den kurzfristigen Zins setzen kann und sie dabei auf den Output-Gap sowie die Inflation reagiert.

- Es wird die Erwartungshypothese in der folgenden Form angenommen:¹⁹

$$R_t = \frac{1}{2}(i_t + E_t[i_{t+1}]).$$

R_t ist dabei der Zinssatz für die Maturität von zwei Perioden und $E_t[\cdot]$ steht für den Erwartungswert gegeben alle Informationen im Zeitpunkt t .

Löst man die Gleichungen nach dem erwarteten Output-Gap, erhält man die folgende Gleichung:

$$E_t[x_{t+1}] = \frac{2}{g_x}(R_t - i_t) + \frac{1 - g_i}{g_x}(i_t - \pi^*) + \frac{g_\pi}{g_x}(\pi^* - \pi_t - ax_t), \quad (5.4)$$

in der der erwartete Output-Gap eine lineare Funktion in der Zinsdifferenz ($R_t - i_t$) ist. Die Zinsdifferenz ist somit in diesem Modell ein Frühindikator.

Alle bisher dargestellten Erklärungsansätze gehen im wesentlichen auf die Gültigkeit der Erwartungshypothese zurück. Es besteht starke empirische Evidenz, dass dieser Zusammenhang unmodifiziert nicht gilt. Vielmehr kann von einer zeitvariierenden Prämie für langfristige Titel

¹⁹In dieser vereinfachten Form bleiben Zinseszins-Effekte unberücksichtigt.

ausgegangen werden. Bereits Hicks (1939) weist darauf hin, dass die Identität zwischen langfristigen Zinsen und zukünftigen kurzfristigen Zinsen wegen der Liquiditätspräferenzen der Agenten nicht gelten muss. Die Liquiditätspräferenz steht im Zusammenhang der Risikoaversion und der Risikostruktur. Es erscheint plausibel, dass diese Größen in der Zeit variieren. Der Kern des Modells von Estrella (2005) ist jedoch, dass eine lineare Beziehung zwischen realem Output und der Zinsdifferenz besteht und dass dieser Zusammenhang von den Reaktionsparametern der Geldpolitik abhängt. Entsprechend führen Änderungen in den Reaktionsparametern der Geldpolitik auch zu Änderungen im Vorlaufverhalten der Zinsdifferenz. Ausgehend von dem Modell von Estrella (2005) lässt sich die Hypothese formulieren, dass die Veränderungen des Vorlaufverhaltens der Zinsdifferenz durch Änderungen in der Geldpolitik hervorgerufen werden. Um diese Hypothese der direkten Abhängigkeit der Zeitvariation der Vorlaufeigenschaften der Zinsdifferenz von der Zeitvariation in der Geldpolitik zu überprüfen wird daher in Abschnitt 5.3 ein Modell mit gemeinsamer Zeitvariation der Parameter eingeführt. Im folgenden Abschnitt wird in Hinleitung auf dieses gemeinsame Modell die Zeitvariation der Vorlaufeigenschaften der Zinsdifferenz anhand eines Markov-Switching-Modells diskutiert.

5.2.4 Empirische Ergebnisse zeitvariierender Vorlaufeigenschaften

In der vorliegenden Arbeit wird die Zeitvariation des Vorlaufverhaltens der Zinsdifferenz mit Hilfe eines Markov-Switching-Prozesses modelliert. Das Vorhersagemodell nimmt die folgende Form an:

$$y_t^k = \alpha + \beta_{v_t} S_t + \varepsilon_t, \quad \varepsilon_t \stackrel{i.i.d.}{\sim} N(0, \sigma^2), \quad (5.5)$$

wobei die Zustandsvariable v_t einem bereits in Abschnitt 2.1.2 besprochenen Markov-Prozess folgt. Dieses Modell wird mit dem linearen Modell in Gleichung 5.3 verglichen. Sowohl für Deutschland wie für die USA werden im Markov-Switching-Modell zwei Zustände unterstellt.²⁰ Das Modell hat entsprechend neben den Parametern in Gleichung 5.5 zwei Übergangs- bzw. Bleibewahrscheinlichkeiten als zusätzliche Parameter, $P(v_t = 0 | v_{t-1} = 0) = p_{00}^v$ und $P(v_t = 1 | v_{t-1} = 1) = p_{11}^v$. Das Markov-Switching-Modell wird außerdem in einer restringierten Fassung verwendet, die nur einen einmaligen Regimewechsel bzw. Bruch zulässt. Die Restriktion liegt auf den Übergangswahrscheinlichkeiten in Form von $p_{11}^v = 1$.²¹ Die Bruchspezifikation lehnt sich an die Arbeit von Estrella et al. (2003) an und überprüft, ob ein einmaliges Ereignis die

²⁰Ein Markov-Switching-Modell mit drei Zuständen wird weder für Deutschland noch für die USA präferiert. Vorab Maximum-Likelihood-Schätzungen ergeben einen Wert der Log-Likelihood von -211,425 im Fall von drei Zuständen. Das beschränkte Markov-Switching-Modell mit zwei Zuständen hat einen Log-Likelihood-Wert von -214,311 im Fall der USA. Für Deutschland ist die Differenz noch geringer.

²¹In der Literatur werden Schwelleneffekte als mögliche Form der Nicht-Linearität diskutiert, siehe Galbraight und Tkacz (2000), Venetis et al. (2003) oder Duarte et al. (2005). In Hogrefe (2007) werden diese zusätzlich zum Markov-Switching diskutiert. Schwelleneffekte substituieren nicht die hier besprochenen Formen der Zeitvariation und werden daher an dieser Stelle vernachlässigt.

Veränderungen der Vorlaufeigenschaften am besten modellieren kann.

Sowohl für die USA wie auch für Deutschland gibt es Evidenz, dass sich die Volatilität des Wachstums im Verlauf der Zeit verringert bzw. verändert hat.²² Um zu kontrollieren, dass die Zeitvariation des Regressors im homoskedastischen Modell nicht diesem Umstand geschuldet ist, wird zusätzlich ein unabhängiger Markov-Switching-Prozess für die Varianz unterstellt. Es ergibt sich das folgende Modell:

$$y_t^k = \alpha + \beta S_t + \sigma_{w_t} e_t, \quad e_t \stackrel{i.i.d.}{\sim} N(0, 1), \quad (5.6)$$

wobei die Zustandsvariable w_t zwei mögliche Zustände annehmen kann und einer Markov-Kette mit $P(w_t = 0 | w_{t-1} = 0) = p_{00}^w$ und $P(w_t = 1 | w_{t-1} = 1) = p_{11}^w$ folgt. Analog wird auch in den Modellen mit zeitvariierenden Vorlaufeigenschaften eine entsprechende Modellierung der Varianz vorgenommen:

$$y_t^k = \alpha + \beta_{v_t} S_t + \sigma_{w_t} e_t, \quad e_t \stackrel{i.i.d.}{\sim} N(0, 1), \quad (5.7)$$

Ebenfalls wird für diese Modellvariante ein einzelner Bruch in der Mittelwertgleichung in Form einer restringierten Markov-Kette berücksichtigt ($p_{11}^v = 1$). Insgesamt werden folglich drei Modelle diskutiert: (1) das lineare Modell aus Gleichung 5.3, (2) das Markov-Switching-Modell aus Gleichung 5.5 sowie (3) eine restringierte Variante dieses Modells in Form eines einzelnen Bruchs. Schließlich werden für alle drei Modelle zwei Spezifikationen der Varianz unterstellt: (a) homoskedastische Fehlervarianz und (b) Markov-Switching-Prozess in der Fehlervarianz. Für alle Modellvarianten werden die a posteriori Verteilungen der Parameter mit Hilfe des Gibbs-Sampler ermittelt und die Marginalen Likelihoods anhand der Methode von Chib (1995) berechnet, um die Modelle zu vergleichen. Die in diesem Kapitel verwendeten Gibbs-Sampler sind in Anhang A.6 angegeben. Dort finden sich auch die Hyperparameter der a priori Verteilungen aller in diesem Kapitel verwendeten Modelle.

Ergebnisse für die USA

Die verwendeten Daten liegen quartalsweise vor und stammen für die USA wie auch für Deutschland vom OECD Statistical Compendium Ausgabe 2003. Es wird jeweils der Zeitraum zwischen 1974 und 2002 betrachtet. Der Beginn der Untersuchung wurde auf 1974 gelegt um mögliche Einflüsse durch den Übergang zum flexiblen Wechselkurssystem nach dem Ende des Bretton-Woods-Systems auszuschließen. Die Zinsdifferenz wird aus den Zinsen 10 jähriger Staatspapiere und einem dreimonatigen Zinssatz gebildet. Als Abhängige dient die jährliche Wachstumsrate des realen BIP. In Tabelle 5.1 sind die Ergebnisse des linearen Modells aus Gleichung 5.3, des Markov-Switching-Modells mit homoskedastischer Varianz aus Gleichung 5.5 und dessen

²²Für die USA siehe unter anderem Kim und Nelson (1999b) oder McConnell und Perez-Quiros (2000); für Deutschland siehe Kapitel 4.

restringierte Version, die nur einen Wechsel zulässt, angegeben. In Abbildung 5.1 sind die Wahrscheinlichkeiten der Zustände abgetragen. Im unrestringierten Fall (linkes Bild) findet sich viel Wahrscheinlichkeitsmasse im ersten Teil der Stichprobe für den Zustand 0, wobei β_0 eindeutig positiv und im Mittel größer eins ist. Nach 1984 bis etwa 1995 ist die Wahrscheinlichkeit für den Zustand 1 nahezu 1. β_1 ist im Mittel 0,318 und das 2,5 % Perzentil der a posteriori Verteilung ist negativ. Die Vorlaufeigenschaften der Zinsdifferenz haben sich abgeschwächt. Ende der 90er Jahre baut sich wiederum Wahrscheinlichkeitsmasse für den Zustand 0 auf, die sich allerdings zum Ende der Stichprobe 2002 verringert. Das restringierte Modell zeigt einen Bruch um 1984 auf.²³ Entsprechend der Marginalen Likelihood wird die Restriktion vorgezogen. Die Zeitvariation der Vorlaufeigenschaften der Zinsdifferenz in den USA lassen sich im homoskedastischen Modell also am besten als Bruch darstellen, nach welchem die Verteilung von β_1 um die Null zentriert ist.

In Tabelle 5.2 sind die Ergebnisse unter Berücksichtigung eines Markov-Switching-Prozesses der Fehlervarianz angegeben. Abbildung 5.2 zeigt die Wahrscheinlichkeitsverteilung der Varianzregime im linearen Modell. Die Marginale Likelihood zeigt an, dass die homoskedastische Modellierung in keinem der drei Modellvarianten bevorzugt wird und starke Evidenz für einen Markov-Switching-Prozess in den Fehlern besteht. Die Berücksichtigung der Heteroskedastie macht die Zeitvariation der Vorlaufeigenschaften jedoch nicht überflüssig. Die Evidenz steigt sogar an, was mit einer eindeutigeren Zuordnung der Regime im Fall des unrestringierten Markov-Switching im Mittelwert einhergeht, siehe Abbildung 5.3 links. Die Standardabweichungen sowie die Mittelwerte der Parameter β_0 und β_1 sinken, die Differenz zwischen beiden bleibt erhalten. Die Verteilung von β_1 hat mehr Masse im negativen Bereich. Im Fall des restringierten Modells ergibt sich die gleiche Datierung des Bruchs wie im homoskedastischen Modell, siehe Abbildung 5.4 links. Hier ist der Mittelwert von β_1 negativ. Der Vergleich der Marginalen Likelihoods des restringierten Markov-Switching-Modells mit dem Unrestringierten zeigt in diesem Fall etwas stärkere Evidenz für die Hypothese eines einzelnen Bruchs an. Insgesamt ist die Evidenz für eine Zeitvariation des Vorlaufverhaltens der Zinsdifferenz in den USA sehr stark. Abschließend sei darauf verwiesen, dass um 1984 sowohl eine starke Veränderung des Vorlaufverhaltens wie auch der Fehlervarianz aufgetreten ist. In den Abbildungen 5.3 und 5.4 sind auf der rechten Seite jeweils die Wahrscheinlichkeiten für den Zustand 0 der Varianzen dargestellt, die im Vergleich untereinander nahezu identisch sind. Verglichen zu den Varianzen im linearen Modell gibt es Unterschiede Anfang der 90er Jahre. Die Berücksichtigung des Markov-Switching in der Mittelwertgleichung führt zum früheren Ende einer Phase hoher Varianz. Insgesamt lässt sich für die Vorlaufeigenschaften der Zinsdifferenz in den USA festhalten, dass diese nach 1984 schwächer geworden sind. Nimmt man das restringierte Markov-Switching-Modell an, hat die Zinsdifferenz nach 1984 keine Vorlaufeigenschaften zum BIP-Wachstum in einem Horizont von einem Jahr

²³Estrella et al. (2003) finden für die USA im Rahmen eines Strukturbruchttests ebenfalls, dass sich die Vorlaufeigenschaften der Zinsdifferenz in 1984 verschlechtert haben.

Tabelle 5.1: Ergebnisse für das Vorhersagemodell – USA – Teil (a)

Lineares Modell							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	2,612	0,189	2,236	2,301	2,613	2,926	2,981
β	0,630	0,092	0,448	0,477	0,631	0,779	0,808
σ^2	3,409	0,464	2,615	2,719	3,369	4,229	4,403
Likelihood -224,851			Marginale Likelihood -234,379				
Modell in Gleichung 5.3.							
MS-Modell							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	2,724	0,295	2,136	2,236	2,727	3,210	3,306
β_0	1,541	0,549	0,876	0,949	1,412	2,784	3,127
β_1	0,318	0,178	-0,045	0,017	0,318	0,607	0,650
σ^2	2,593	0,404	1,908	1,997	2,559	3,312	3,488
p_{00}^v	0,830	0,096	0,591	0,644	0,847	0,952	0,963
p_{11}^v	0,901	0,057	0,768	0,795	0,910	0,974	0,982
Likelihood -217,915			Marginale Likelihood -229,889				
Modell in Gleichung 5.5.							
Restringsiertes MS-Modell (Bruch)							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	3,103	0,386	2,336	2,469	3,105	3,739	3,859
β_0	1,037	0,234	0,578	0,648	1,034	1,424	1,499
β_1	0,127	0,256	-0,359	-0,285	0,121	0,554	0,642
σ^2	3,007	0,465	2,246	2,339	2,956	3,850	4,081
p_{00}^v	0,973	0,020	0,924	0,936	0,977	0,995	0,997
Likelihood -214,906			Marginale Likelihood -229,059				
Modell in Gleichung 5.5, wobei $p_{11}^v = 1$.							

A posteriori Verteilungen ermittelt per Gibbs-Sampling.

Abbildung 5.1: Homoskedastische MS-Modelle – USA





Abbildung 5.2: Lineares Modell mit MS-Varianz – USA



mehr.

Ergebnisse für Deutschland

Wie für die USA wird als Untersuchungszeitraum 1974 bis 2002 angenommen. Mit dem Übergang von der Deutschen Mark zum Euro in 1999 wird als kurzfristiger Zinssatz vom Zins des Fidor zum Euribor gewechselt. Vor 1999 werden die Differenzen der Zinsen der 10 jährigen Staatspapiere zu den Fidor-Zinsen und nach 1999 zu den Euribor-Zinsen gebildet. In Tabelle 5.3 sind die Ergebnisse der drei zu vergleichenden Modelle mit der homoskedastischen Fehlervarianz dargestellt. Entsprechend der Marginalen Likelihood wird das Modell mit konstanten Vorlaufe-

Tabelle 5.2: Ergebnisse für das Vorhersagemodell – USA – Teil (b)

Lineares Modell mit MS-Varianz							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	3,027	0,234	2,570	2,640	3,031	3,399	3,490
β	0,440	0,151	0,088	0,150	0,459	0,661	0,699
σ_0^2	6,088	1,738	3,752	3,981	5,733	9,467	10,488
σ_1^2	0,565	0,217	0,311	0,339	0,534	0,863	0,945
p_{00}^w	0,853	0,072	0,687	0,723	0,864	0,950	0,960
p_{11}^w	0,888	0,060	0,744	0,778	0,899	0,965	0,973
Likelihood -216,000				Marginale Likelihood -226,148			
Modell in Gleichung 5.6.							
MS-Modell mit MS-Varianz							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	3,197	0,242	2,713	2,802	3,196	3,581	3,675
β_0	0,864	0,172	0,554	0,599	0,856	1,158	1,223
β_1	0,025	0,097	-0,156	-0,126	0,022	0,191	0,228
σ_0^2	5,786	1,497	3,598	3,828	5,541	8,528	9,339
σ_1^2	0,482	0,107	0,312	0,333	0,469	0,672	0,726
p_{00}^v	0,901	0,045	0,794	0,818	0,908	0,962	0,970
p_{11}^v	0,870	0,062	0,725	0,754	0,880	0,954	0,963
p_{00}^w	0,910	0,046	0,796	0,822	0,918	0,969	0,975
p_{11}^w	0,894	0,058	0,754	0,785	0,904	0,970	0,978
Likelihood -201,205				Marginale Likelihood -216,616			
Modell in Gleichung 5.7.							
Restringiertes MS-Modell (Bruch) mit MS-Varianz							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	3,708	0,228	3,241	3,332	3,714	4,073	4,139
β_0	0,992	0,204	0,633	0,680	0,981	1,333	1,398
β_1	-0,085	0,104	-0,281	-0,251	-0,088	0,091	0,124
σ_0^2	5,921	1,538	3,671	3,905	5,667	8,850	9,700
σ_1^2	0,562	0,132	0,354	0,378	0,545	0,800	0,866
p_{00}^v	0,974	0,018	0,930	0,940	0,979	0,995	0,997
p_{00}^w	0,896	0,049	0,778	0,804	0,903	0,961	0,969
p_w^{11}	0,869	0,064	0,720	0,752	0,878	0,955	0,965
Likelihood -201,243				Marginale Likelihood -215,156			
Modell in Gleichung 5.7, wobei $p_{11}^v = 1$.							

A posteriori Verteilungen ermittelt per Gibbs-Sampling.

Abbildung 5.3: MS-Modell mit MS-Varianz – USA




Abbildung 5.4: Restringiertes MS-Modell mit MS-Varianz – USA




Tabelle 5.3: Ergebnisse für das Vorhersagemodell – Deutschland – Teil (a)

Lineares Modell							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	1,507	0,211	1,098	1,166	1,507	1,851	1,917
β	0,532	0,112	0,316	0,347	0,532	0,715	0,758
σ^2	3,236	0,442	2,495	2,590	3,192	4,031	4,219
Likelihood -220,976				Marginale Likelihood -229,148			
Modell in Gleichung 5.3.							
MS-Modell							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	1,616	0,224	1,184	1,250	1,614	1,984	2,053
β_0	0,747	0,271	0,441	0,482	0,723	1,036	1,141
β_1	0,067	0,284	-0,499	-0,395	0,064	0,526	0,592
σ^2	2,919	0,443	2,156	2,258	2,886	3,702	3,873
p_{00}^v	0,866	0,109	0,564	0,637	0,897	0,976	0,983
p_{11}^v	0,812	0,114	0,525	0,588	0,834	0,954	0,968
Likelihood -218,946				Marginale Likelihood -230,436			
Modell in Gleichung 5.5.							
Restringiertes MS-Modell (Bruch)							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	1,590	0,375	0,851	0,971	1,588	2,209	2,320
β_0	0,701	0,229	0,246	0,325	0,704	1,076	1,148
β_1	0,118	0,357	-0,598	-0,492	0,130	0,682	0,792
σ^2	3,159	0,486	2,346	2,455	3,104	4,014	4,230
p_{00}^v	0,959	0,032	0,874	0,894	0,968	0,994	0,996
Likelihood -218,126				Marginale Likelihood -230,589			
Modell in Gleichung 5.5, wobei $p_{11}^v = 1$.							

A posteriori Verteilungen ermittelt per Gibbs-Sampling.

genschaften präferiert.²⁴ Die Evidenz dafür ist allerdings nicht sehr ausgeprägt. Eine Differenz um die 1,3 der logarithmierten Marginalen Likelihoods entspricht nur schwacher Evidenz laut der Skala von Jeffreys (1961), vgl. Anhang A.3. Die Marginalen Likelihoods des restringierten und des unrestringierten Markov-Switching-Modells liegen gleich auf. In beiden Modellen nimmt der Wert von β im zweiten Teil der Stichprobe ab. Der Mittelwert von β_1 ist jeweils nahe Null. Die Wahrscheinlichkeiten des Zustandes 0 (hohes β) sind in Abbildung 5.5 zu finden.

Die Evidenz für eine Zeitvariation des Vorlaufverhaltens ändert sich, wenn die Annahme einer homoskedastischen Fehlervarianz fallengelassen wird. Für das lineare Modell sind die Wahr-


²⁴Estrella et al. (2003) finden für ein Strukturbruchmodell allerdings mit der Industrieproduktion als Abhängigen ebenfalls keine Evidenz für eine Variation der Vorlaufeigenschaften in der Zeit für deutsche Daten.

Tabelle 5.4: Ergebnisse für das Vorhersagemodell – Deutschland – Teil (b)

Lineares Modell mit MS-Varianz							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	1,144	0,184	0,777	0,844	1,144	1,450	1,504
β	0,652	0,093	0,470	0,499	0,652	0,803	0,832
σ_0^2	14,805	5,449	7,557	8,325	13,723	24,734	28,288
σ_1^2	1,722	0,284	1,237	1,305	1,697	2,226	2,353
p_{00}^w	0,952	0,030	0,877	0,896	0,958	0,988	0,991
p_{11}^w	0,755	0,104	0,521	0,564	0,767	0,907	0,926
Likelihood -209,968				Marginale Likelihood -220,479			
Modell in Gleichung 5.6.							
MS-Modell mit MS-Varianz							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	1,256	0,183	0,898	0,958	1,259	1,556	1,612
β_0	0,900	0,122	0,691	0,722	0,887	1,119	1,167
β_1	0,123	0,167	-0,193	-0,144	0,122	0,394	0,450
σ_0^2	14,933	5,322	7,716	8,475	13,918	24,874	28,213
σ_1^2	1,279	0,227	0,900	0,945	1,259	1,679	1,782
p_{00}^v	0,895	0,065	0,731	0,767	0,909	0,974	0,981
p_{11}^v	0,846	0,077	0,668	0,704	0,856	0,952	0,964
p_{00}^w	0,957	0,026	0,894	0,909	0,962	0,988	0,991
p_{11}^w	0,756	0,104	0,527	0,567	0,768	0,908	0,925
Likelihood -202,800				Marginale Likelihood -217,875			
Modell in Gleichung 5.7.							
Restringiertes MS-Modell (Bruch) mit MS-Varianz							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	1,264	0,184	0,902	0,959	1,266	1,566	1,626
β_0	0,822	0,090	0,646	0,676	0,822	0,970	1,000
β_1	0,120	0,146	-0,162	-0,116	0,119	0,361	0,413
σ_0^2	14,487	5,313	7,549	8,249	13,399	24,178	27,754
σ_1^2	1,345	0,235	0,937	0,995	1,329	1,755	1,857
p_{00}^v	0,954	0,032	0,875	0,892	0,961	0,992	0,994
p_{11}^w	0,749	0,102	0,522	0,565	0,759	0,898	0,917
p_{00}^w	0,951	0,030	0,876	0,894	0,956	0,987	0,990
Likelihood -201,775				Marginale Likelihood -217,644			
Modell in Gleichung 5.7, wobei $p_{11}^v = 1$.							

A posteriori Verteilungen ermittelt per Gibbs-Sampling.

Abbildung 5.5: Homoskedastische MS-Modelle – Deutschland



scheinlichkeiten der Varianzen in Abbildung 5.6 zu finden. Zum einen wird entsprechend der Marginalen Likelihood die Modellierung mit einem Markov-Switching-Prozess der Varianz eindeutig favorisiert. Zum anderen hat sich das Verhältnis zwischen zeitinvarianten und zeitvariierenden Vorlaufeigenschaften umgekehrt. Anhand der Marginalen Likelihood lässt sich jedoch nicht entscheiden, ob das restringierte oder das unrestringierte Markov-Switching-Modell vorzuziehen ist. Die Verteilungen der β -Parameter sind von der Lage ähnlich wie die im Falle der homoskedastischen Modelle, wobei die Standardabweichung geringer ist, siehe Tabelle 5.4. Die Wahrscheinlichkeiten des Zustandes 0 sind in Abbildung 5.7 und für das restringierte Modell in Abbildung 5.8 jeweils links zu sehen. Es zeigt sich, dass in den 90er Jahren die Vorlaufeigenschaften der Zinsdifferenz schwächer waren als in den Perioden zuvor. Die Zinsdifferenz hat an Prognosegüte verloren.

Analog zu den USA erhöht sich die Evidenz für die Zeitvariation des Vorlaufverhaltens der Zinsdifferenz, wenn Änderungen in der Varianz berücksichtigt werden, wobei die Inferenz über die Varianzregime nahezu unberührt durch die unterschiedlichen Mittelwertgleichungen ist, vgl. Abbildung 5.6 sowie 5.7 und 5.8 jeweils rechts. Im Falle von Deutschland zeigt sich erst unter Berücksichtigung der Zeitvariation der Varianz Evidenz für eine Verschlechterung der Vorlaufeigenschaften gegen Ende des Stichprobenzeitraums. Die Variation der Vorlaufeigenschaften lässt sich also nicht als Phänomen der Variation der Volatilität des BIP-Wachstums deuten, sondern hat einen eigenständigen Charakter.

Abbildung 5.6: Lineares Modell mit MS-Varianz – Deutschland

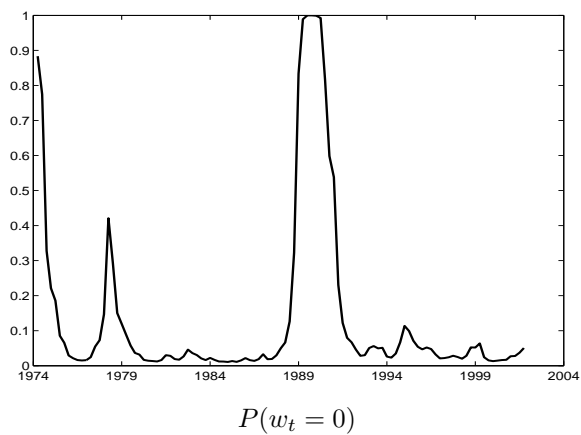


Abbildung 5.7: MS-Modell mit MS-Varianz – Deutschland





Abbildung 5.8: Restringiertes MS-Modell mit MS-Varianz – Deutschland



5.3 Die Rolle der Geldpolitik

5.3.1 Empirische Reaktionsfunktionen der Geldpolitik

In den ökonomischen Theorien zu den Vorlaufeigenschaften der Zinsdifferenz spielen die Erwartungen über kurzfristige Zinsen eine zentrale Rolle. Allgemein unterliegen kurzfristige Zinsen starken Einflüssen der Geldpolitik, was, sofern angenommen werden kann, dass die Geldpolitik auf die Konjunktur reagiert, einen möglichen Übertragungskanal von Konjunkturerwartungen auf die langfristigen Zinsen manifestiert. Vor diesem Hintergrund ist die Hypothese, dass die Geldpolitik die Vorlaufeigenschaften der Zinsdifferenz bestimmt, zu verstehen. Das bereits angesprochene Modell von Estrella (2005) formuliert die Geldpolitik einer Zentralbank in Form einer Reaktionsfunktion, die die Inflation und den Output-Gap berücksichtigt. Die ursprüngliche Formulierung basiert auf der Arbeit von Taylor (1993), die als eine Art positiver Theorie des Zentralbankverhaltens zu sehen ist. Der (von der Zentralbank) gewünschte kurzfristige Zins ergibt sich in der folgenden Form:

$$i_t^* = \bar{r} + \pi_t + \eta(\pi_t - \bar{\pi}) + \xi x_t, \quad (5.8)$$

wobei \bar{r} der Realzins, $\bar{\pi}$ die gewünschte Inflation und $\pi_t - \bar{\pi}$ die entsprechende realisierte Abweichung davon ist. Der Output-Gap wird durch x_t dargestellt. Grundlegend für Reaktionsfunktionen dieser Art ist, dass kurzfristige Zinssätze das wesentliche Instrument der Geldpolitik sind und dass Zentralbanken ein Konjunktur- sowie ein Inflationsziel verfolgen. Der Gewichtung der Ziele entspricht das Verhältnis der Reaktionsparameter η und ξ zueinander. Taylor (1993) nimmt für η und ξ jeweils den Wert 0,5 an, wobei zu berücksichtigen ist, dass π_t einmal bereits in der Gleichung enthalten ist.

Diese grundlegende Formulierung hat in verschiedenen Varianten Eingang in die empirische Literatur gefunden. Eine wesentliche Erweiterung ist die Glättung der Zinsen. Es ist zu beobachten, dass Zinsen eine hohe Autokorrelation aufweisen und Zinsschritte nicht in der Stärke vorgenommen werden, wie die Änderungen der eventuell bestimmenden Faktoren dies vorgeben. Goodfriend (1991) begründet diese Glättung mit dem Argument, dass zusätzliche Turbulenzen auf den Finanzmärkten vermieden werden sollen. Ein Modell, das die Glättung der Zinssätze berücksichtigt, lautet wie folgt:²⁵

$$i_t = (1 - \rho)i_t^* + \rho i_{t-1} \quad (5.9)$$

wobei die Zentralbank nicht mehr den eigentlich gewünschten Zins i_t^* , sondern den geglätteten Zins i_t setzt.

Da in der Regel der Realzinssatz und eventuell das Inflationsziel der Zentralbank unbekannt sind, ergibt sich im Zusammenspiel der Gleichungen 5.8 und 5.9 folgendes Schätzmodell:

$$i_t = (1 - \rho)[\zeta + (1 + \eta)\pi_{t+j} + \xi x_{t+k}] + \rho i_{t-1} + \epsilon_t. \quad (5.10)$$

In der Formulierung von Taylor (1993) gilt $j = k = 0$. In der Regel werden, um Endogenitätsprobleme zu vermeiden, in empirischen Schätzmodellen negative Werte für j und k angenommen, siehe zum Beispiel Carstensen (2006). In der Arbeit von Clarida et al. (2000) wird explizit eine vorausschauende Reaktionsfunktion unterstellt. In der Schätzgleichung sind j und k positiv. Das Endogenitätsproblem wird mit Hilfe einer Instrumentvariablenschätzung angegangen. In der hier vorliegenden Arbeit werden j und k jeweils auf -1 gesetzt, so dass die Regressoren exogen sind.²⁶

5.3.2 Zeitvariation der Geldpolitik

Das Thema der Zeitvariation der Geldpolitik nimmt in der empirischen-makroökonomischen Literatur einen großen Stellenwert ein. Modelle, die der Gleichung 5.10 ähneln, spielen dabei häufig eine Rolle die Geldpolitik zu quantifizieren. Judd und Rudebusch (1998) sowie Clarida et al. (2000) schätzen das Modell aus Gleichung 5.10 für verschiedene Zeitperioden, die sich nach den Amtszeiten der Vorsitzenden der Zentralbank der USA richten, um zu überprüfen, ob der Wechsel des Vorsitzes zu signifikanten Veränderungen der Geldpolitik geführt hat.

Da institutionelle Wechsel nicht gleichzeitig einen Wechsel der Geldpolitik bedeuten müssen bzw. auch bei bestehenden institutionellen Rahmen Änderungen der Geldpolitik auftreten können, haben Regime-Wechsel-Modelle Eingang in die empirische Forschung zur Geldpolitik bekommen. Basierend auf der Arbeit von Clarida et al. (2000) verwendet Kim (2004) ein restringiertes Markov-Switching-Modell um den a priori festgelegten Bruchpunkt der US-Geldpolitik (Wechsel

²⁵Im theoretischen Modell von Estrella (2005) hat die Glättung der Zinssätze ebenfalls Eingang gefunden.

²⁶In Hogrefe (2007) wird gezeigt, dass sich die Ergebnisse durch die Wahl einer vorausschauenden Reaktionsfunktion qualitativ im Hinblick auf die Verbindung zu den Vorlaufeigenschaften der Zinsdifferenz nicht ändern.

von Volcker zu Greenspan) mit einem frei geschätzten zu vergleichen. Kim (2004) verwendet eine vorausschauende Reaktionsfunktion der Geldpolitik und führt die Instrumentvariablen-schätzung für Markov-Switching-Modelle ein. Weitere Beispiele von Markov-Switching-Modellen, die an die Taylor-Regel angelehnte Reaktionsfunktionen verwenden, sind für US-Daten in Bueno (2004) und Assenmacher-Wesche (2006) zu finden. Letztere wendet den Modellrahmen auch auf deutsche Daten an. Ein Markov-Switching-Modell für das Verhalten der Bundesbank ist ferner in Kuzin (2006) zu finden. Markov-Switching-VAR-Modell zur Analyse der Geldpolitik finden sich in Valente (2003), der mit Daten der G 7 Länder arbeitet, in Owyang und Ramey (2004) und in Sims und Zha (2006). Die letzt genannten analysieren US-Daten. Auffallend beim Vergleich der verschiedenen Studien ist, dass die Inferenz über die Zustände der Geldpolitik zum Teil stark zwischen den Studien variiert. Bereits Detailveränderungen haben offensichtlich einen Einfluss auf die Inferenz. Passend dazu ist das Ergebnis von Sims und Zha (2006), die mit Bayesianischen Methoden ein Modell mit Regimewechseln ausschließlich in der Varianz und nicht in der Mittelwertgleichung favorisieren.

Es ist nicht Gegenstand dieser Arbeit das “richtige” Regime-Wechsel-Modell für die Geldpolitik in den USA bzw. in Deutschland zu finden. Das folgende Markov-Switching-Modell einer Reaktionsfunktion der Geldpolitik dient vielmehr dem Vergleich mit einem gemeinsamen Markov-Switching-Modell von Geldpolitik und Vorlaufeigenschaften der Zinsdifferenz:

$$i_t = (1 - \rho)[\zeta_{u_t} + \eta_{u_t}\pi_{t+j} + \xi_{u_t}x_{t+k}] + \rho i_{t-1} + \sigma_{z_t}e_t, \quad e_t \sim N(0, 1), \quad (5.11)$$


wobei u_t einem Markov-Prozess mit zwei Zuständen folgt und z_t einen (optionalen) Markov-Prozess für die Fehlervarianz repräsentiert. Wie in Kuzin (2006) unterliegen die Reaktionsparameter η und ξ sowie das implizite Inflationsziel ζ den Regimewechseln. Die zusätzliche Option heteroskedastischer Fehler ist angelehnt an Assenmacher-Wesche (2006). Als Maß für die Inflation werden in der empirischen Anwendung die Wachstumsraten des Konsumentenpreisindex verwendet. Ein Maß für den Output-Gap wird mit Hilfe des Hodrick-Prescott-Filters ermittelt.²⁷

Die Abbildung 5.9 zeigt in der linken Hälfte die Wahrscheinlichkeiten der Zustände der Geldpolitik in der Zeit, die aus der Bayesianischen Schätzung des Modells in Gleichung 5.11 für die USA gewonnen werden. Es fällt auf, dass sich ab 1979 Wahrscheinlichkeitsmasse für den Zustand 0 aufbaut. Dies ist begleitet von einem Regimewechsel bzw. einer zeitweisen Zunahme in der Varianz der Geldpolitik.²⁸ Um 1984/1985 nimmt die Varianz der Geldpolitik wieder ab und es wird mehr Wahrscheinlichkeit für den Zustand 1 der Geldpolitik aufgebaut. In der Mitte der 90er Jahre nimmt die Wahrscheinlichkeit für den Zustand 0 wieder zu. Wie bereits

²⁷Die zugrunde liegenden Daten sind dem OECD Statistical Compendium 2003 entnommen.


²⁸Die Zentralbank der USA ist in der Zeit nach 1979 vom Zinsziel abgerückt und erst nach Eindämmung der Inflation dahin zurückgekehrt, vgl. Kim (2004). Abgesehen von dieser möglichen Erklärung für das Varianzverhalten können die Zustandswahrscheinlichkeiten nur sehr schwer mit bedeutenden geldpolitischen Ereignisse, wie zum Beispiel dem Wechsel der Vorsitzenden der US Zentralbank in 1987, überein gebracht werden.

Abbildung 5.9: Markov-Switching-Modell der Geldpolitik – USA



erwähnt gibt es verschiedene Charakterisierungen der Zustandsabhängigkeit der Geldpolitik in den USA. Diese ist mit keiner der vorher genannten deckungsgleich. Auch lassen sich die Ergebnisse schwerlich mit institutionellen Veränderungen der Zentralbank, wie dem Wechsel des Vorsitz von Volcker zu Greenspan, erklären. Es ist jedoch festzustellen, dass ein Ergebnis von Sims und Zha (2006) hier reproduziert wird. Es gibt entsprechend der Marginalen Likelihood keine Evidenz für Zustandswechsel in der Mittelwertgleichung, sondern nur für Zustandswechsel in der Varianz. Die Marginale Likelihood für das Modell aus Gleichung 5.11 beträgt $-74,184$, wobei die Marginale Likelihood für ein Modell, das linear in der Mittelwertgleichung ist und eine Markov-Switching-Varianz hat, mit $-68,365$ evident besser abschneidet und dies trotz einer erheblichen Log-Likelihood Differenz zu Gunsten des höher parametrisierten Modells ($-34,236$ und $-43,979$). Mit Hinblick auf die Hypothese der gemeinsamen Zustandsabhängigkeit zwischen Vorlaufeigenschaften der Zinsdifferenz und Geldpolitik spricht die mangelnde Evidenz für die Zeitvarianz der Geldpolitik im Vergleich zur eindeutigen Evidenz für die Zeitvarianz der Vorlaufeigenschaften gegen die Hypothese. Jedoch ist dies nicht hinreichend. Auch wenn die Daten zur Geldpolitik alleine keine Evidenz aufweisen, ist es möglich, dass die gemeinsame Inferenz über die Daten zur Geldpolitik und der Vorlaufeigenschaften die zugrunde liegende Zustandsabhängigkeit bedeutend besser aufdeckt. Sofern beide Prozesse die gleiche Zustandsabhängigkeit haben, sollte die Modellierung einer gemeinsamen Zustandsabhängigkeit zu einer eindeutigen Verbesserung führen und die gemeinsame Modellierung dann auch die Inferenz über die Zustände der Geldpolitik verbessern. Erst das Verwerfen der gemeinsamen Modellierung impliziert hinreichende Evidenz gegen eine gemeinsame Zustandsabhängigkeit. Hierbei ist auch zu beachten, dass es augenscheinlich Ähnlichkeiten im Verlauf der Zustände der Vorlaufeigenschaften der Zinsdifferenz und der Geldpolitik gibt, vgl. Abbildung 5.3 und 5.9 jeweils links. Bildet man in beiden

Abbildung 5.10: Markov-Switching-Modell der Geldpolitik – Deutschland



Fällen aus den dort dargestellten Wahrscheinlichkeiten die erwarteten Zustände und führt einen χ^2 -Unabhängigkeitstest von Pearson für beide 0/1-Zeitreihen durch, wird die Hypothese der Unabhängigkeit zum 5% Niveau verworfen. Dies kann neben den auf dem Modell von Estrella (2005) gestützten theoretischen Überlegungen als Indiz für eine gemeinsame Zustandsabhängigkeit gewertet werden, die schließlich im folgenden Teilabschnitt überprüft wird.

Abbildung 5.10 zeigt die Wahrscheinlichkeiten der Zustände der deutschen Geldpolitik. Im Gegensatz zu den USA wird hier eine homoskedastischen Fehlervarianz unterstellt. Diese stimmen im wesentlichen mit den Ergebnissen von Kuzin (2006) überein, die ebenfalls in den Jahren um die Wiedervereinigung eine von den sonstigen Jahren abweichende Geldpolitik konstatieren.²⁹ Vergleicht man wesentliche geldpolitische Ereignisse mit der Inferenz über die Zustände fällt der Anstieg der Wahrscheinlichkeit in 1979 auf, dem der Beginn des Europäischen Währungsraums entspricht. Während in den starken Anstieg der Wahrscheinlichkeit des Zustandes 1 in den ersten Jahren der 90er Jahre der Vertrag von Maastricht fällt. Diese Koinzidenzen sollten allerdings nicht überbewertet werden, da diese Europäisierungsschritte der Geldpolitik zu jeweils entgegengesetzten Bewegungen eintreffen.³⁰ Ferner ist auch hier einzuwenden, dass keine Evidenz für die Zeitvarianz der Geldpolitik vorliegt. Die Marginale Likelihood des Markov-Switching-Modells beträgt -78,192 und ist niedriger als die des linearen Modells der Geldpolitik aus Gleichung 5.10 mit -76,045. Auch hier gilt, dass die fehlende Evidenz für die Zeitvarianz der Geldpolitik noch kein hinreichendes Argument gegen die gemeinsame Zustandsabhängigkeit von

²⁹Der Stichprobenzeitraum beinhaltet den Übergang von der Deutschen Mark zum Euro in 1999. Entsprechend wird als Abhängige nach 1999 der Euro-Zinssatz verwendet. Es wird also ein geldpolitisches Modell über die Einführung des Euro hinaus behauptet. Wie auch der Vergleich mit den Ergebnissen in Kuzin (2006) zeigt, wo der Stichprobenzeitraum 1999 abbricht, ändert die Fortschreibung der Geldpolitik über 1999 hinaus die Ergebnisse nicht substantiell.

³⁰Siehe auch Hogrefe (2007).

Geldpolitik und Vorlaufeigenschaften ist.

5.3.3 Gemeinsames Markov-Switching-Modell

Die Hypothese, dass die Vorlaufeigenschaften der Zinsdifferenz und die Geldpolitik die gleiche Zustandsabhängigkeit haben, wird mit Hilfe eines gemeinsamen Markov-Switching-Modells für die Geldpolitik und das Vorhersagemodell überprüft, in welchem die Parameter beider Gleichungen dem selben Markov-Prozess folgen. Die Marginale Likelihood für das gemeinsame Modell wird dazu der Marginalen Likelihood der getrennten Modelle gegenübergestellt.

Das gemeinsame Markov-Switching-Modell nimmt die folgende Form an:

$$\begin{aligned} i_t &= (1 - \rho)(\zeta_{u_t} + \eta_{u_t}\pi_{t+j} + \xi_{u_t}x_{t+k}) + \rho i_{t-1} + \sigma_{i,z_t} \varepsilon_t \\ y_t^k &= \alpha + \beta_{u_t} S_t + \sigma_{\Delta y, w_t} \varepsilon_t. \end{aligned} \quad (5.12)$$

Von der unbeobachtbaren Zustandsvariable u_t hängen hier die Reaktionsparameter und das implizite Inflationsziel der Geldpolitik sowie der Vorlaufparameter β ab.

Das gemeinsame Markov-Switching-Modell aus Gleichung 5.12 ist eine Restriktion eines Modells, das sich aus den zwei Gleichungen 5.7 und 5.11 zusammensetzt. Am besten verdeutlichen kann man die Restriktion, wenn man die beiden Zustandsvariablen u_t und v_t der Mittelwertgleichungen der Gleichungen 5.7 und 5.11 in eine Zustandsvariable uv_t überführt. u_t und v_t können jeweils die Werte 0 oder 1 annehmen. uv_t sei wie folgt definiert:

$$uv_t = \begin{cases} 1 & \text{wenn } u_t = 0 \text{ und } v_t = 0, \\ 2 & \text{wenn } u_t = 0 \text{ und } v_t = 1, \\ 3 & \text{wenn } u_t = 1 \text{ und } v_t = 0, \\ 4 & \text{wenn } u_t = 1 \text{ und } v_t = 1. \end{cases}$$

Die Übergangsmatrix der Zustandsvariable uv_t setzt sich nun aus den Übergangswahrscheinlichkeiten der Modelle 5.7 und 5.11 wie folgt zusammen:

$$P^{uv} = \begin{bmatrix} p_{11}^{uv} & p_{21}^{uv} & p_{31}^{uv} & p_{41}^{uv} \\ p_{12}^{uv} & p_{22}^{uv} & p_{32}^{uv} & p_{42}^{uv} \\ p_{13}^{uv} & p_{23}^{uv} & p_{33}^{uv} & p_{43}^{uv} \\ p_{14}^{uv} & p_{24}^{uv} & p_{34}^{uv} & p_{44}^{uv} \end{bmatrix} = \begin{bmatrix} p_{00}^u p_{00}^v & p_{00}^u p_{10}^v & p_{10}^u p_{00}^v & p_{10}^u p_{10}^v \\ p_{00}^u p_{01}^v & p_{00}^u p_{11}^v & p_{10}^u p_{01}^v & p_{10}^u p_{11}^v \\ p_{01}^u p_{00}^v & p_{01}^u p_{10}^v & p_{11}^u p_{00}^v & p_{11}^u p_{10}^v \\ p_{01}^u p_{01}^v & p_{01}^u p_{11}^v & p_{11}^u p_{01}^v & p_{11}^u p_{11}^v \end{bmatrix}.$$

Das Modell mit zwei unabhängigen Markov-Switching-Prozessen der Mittelwertgleichungen entspricht folglich einem Markov-Switching-Prozess mit der Übergangsmatrix P_{uv} , die vier frei zu schätzende Parameter enthält. Das Modell der Gleichung 5.12 entspricht der Annahme, dass der Zustand der Geldpolitik u_t den der Vorlaufeigenschaften determiniert also $u_t = v_t$. Die

Restriktion führt zu folgender Übergangsmatrix:

$$P^{uv} = \begin{bmatrix} p_{00}^u & 0 & 0 & p_{10}^u \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ p_{01}^u & 0 & 0 & p_{11}^u \end{bmatrix},$$

die nur noch zwei frei zu schätzende Parameter enthält. Die Restriktionen liegen jedoch nicht auf den Parametern p_{00}^v und p_{11}^v . Ein parametrischer Test zu der Hypothese der gemeinsamen Zustandsabhängigkeit ist daher nicht möglich.³¹

Die Verwendung eines gemeinsamen Markov-Switching-Modells basiert auf der Überlegung, dass die Marktteilnehmer, die mit zinstragenden Titeln handeln, entsprechend dem Verhalten der Geldpolitik und ihren Konjunktur- und Inflationserwartungen agieren. Dabei wird durch die Modellierung mit nur zwei Zuständen unterstellt, dass die Geldpolitik ohne Zeitverzug wahrgenommen werden kann. Es bietet sich an diese strikte Annahme abzuschwächen und eine eventuelle Reaktionszeit auf Veränderungen der Geldpolitik zu bedenken. Unterstellt man, dass die Marktteilnehmer entweder sofort oder erst nach einem Quartal die Geldpolitikänderungen nachvollziehen, ergibt sich folgende Übergangsmatrix:


$$P^{uv} = \begin{bmatrix} p_{11}^{uv} & 0 & p_{31}^{uv} & p_{41}^{uv} \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ p_{14}^{uv} & p_{24}^{uv} & 0 & p_{44}^{uv} \end{bmatrix}.$$

Maximum-Likelihood-Schätzungen für das Modell in Gleichung 5.12, das mit dieser Übergangsmatrix und der Setzung $u_t = uv_t$ modifiziert wird, ergeben nur geringfügige Unterschiede zu Maximum-Likelihood-Schätzungen des Modells in Gleichung 5.12 ohne Modifizierung. Entsprechend wird dieser Fall nicht weiter verfolgt und ausschließlich die striktere Hypothese, dass sich die Geldpolitikänderungen noch im gleichen Quartal auf die Vorlaufeigenschaften auswirken, betrachtet.

Das hier diskutierte Modell mit gemeinsamer Zustandsabhängigkeit ist alternativ zu anderen Ansätzen in der Literatur zu sehen, die darauf basieren das Vorhersagemodell für verschiedene Zeitfenster zu schätzen, deren Einteilung sich nach möglichen institutionellen Wechsellpunkten der Geldpolitik richtet, siehe Estrella (2005). Wenn die Schätzungen von β in den einzelnen Zeitfenstern signifikante Unterschiede aufweisen, ist dies dann als Evidenz für die gemeinsame Zustandsabhängigkeit zu werten. Dieses Vorgehen weist einige Nachteile auf. Neben der bereits erwähnten Kritik, dass tatsächliche Schwankungen der Geldpolitik zeitlich nicht mit institutionellen Veränderungen übereinstimmen müssen und somit kein eigentlicher Beweis für den Zusammenhang zwischen Vorlaufeigenschaften und Geldpolitik erbracht wird, werden Schwankungen von β innerhalb der jeweiligen Zeitfenster unterschlagen, siehe dazu Hogrefe (2007).

³¹Analog zu Abschnitt 2.5 werden daher auch hier Bayesianische Methoden zum Modellvergleich angewendet.

Abbildung 5.11: Gemeinsames Markov-Switching-Modell – USA – Teil (a)



5.3.4 Ergebnisse

Ergebnisse für die USA

Im Folgenden werden die Ergebnisse der gemeinsamen Markov-Switching-Modelle dargestellt und mit denen der getrennten Markov-Switching-Prozesse verglichen. Das gemeinsame Markov-Switching-Modell entspricht der Hypothese, dass die Vorlaufeigenschaften der Zinsdifferenz und die Geldpolitik die gleiche Zustandsabhängigkeit haben, was von der Determination der Vorlaufeigenschaften durch die Geldpolitik impliziert würde. Dem werden die getrennten Markov-Switching-Modelle gegenüber gestellt, wo die Zustände von Geldpolitik und Vorlaufeigenschaften unabhängig voneinander modelliert werden. Tabelle 5.5 gibt die a posteriori Verteilungen der Parameter des gemeinsamen Modells an, wobei hier eine homoskedastische Varianz in der Gleichung für die Vorlaufeigenschaften unterstellt wird ($\sigma_{\Delta y,0}^2 = \sigma_{\Delta y,1}^2$). Vergleicht man die Verteilungen der Parameter der Vorlaufeigenschaften zeigt sich im unrestringierten Fall eine gewisse Abweichung des Mittelwertes von β_1 (1,244) zum Fall des alleinigen Markov-Switching-Modells (1,541). Die Verteilungen überlappen sich jedoch weitestgehend, vgl. Tabelle 5.1 und 5.5. Der leichten Abweichung entspricht, dass die Wahrscheinlichkeit der Zustände sich stark an die Inferenz im alleinigen Markov-Switching-Modell für die Geldpolitik anlehnen, vgl. Abbildung 5.9 links und Abbildung 5.11 links. Insbesondere am Anfang und Ende der Stichprobe kommt es zu Abweichungen im Vergleich zum alleinigen Markov-Switching-Modell der Vorlaufeigenschaften. Abbildung 5.11 rechts zeigt ferner die Wahrscheinlichkeit des Zustandes 0 der Varianz der Geldpolitik. Sie entspricht im Wesentlichen der Darstellung in Abbildung 5.9 rechts, wo ausschließlich die Geldpolitik modelliert ist.

Ferner ist festzuhalten, dass beim Wechsel der Zustände die Änderungen der Parameterwerte

Tabelle 5.5: Gemeinsames Markov-Switching-Modell – USA – Teil (a)

Unrestringiertes Modell							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	2,668	0,362	1,967	2,072	2,668	3,274	3,384
β_0	1,244	0,393	0,618	0,695	1,194	1,966	2,165
β_1	0,405	0,211	-0,043	0,042	0,418	0,727	0,785
$\sigma_{\Delta y}^2$	3,164	0,520	2,294	2,411	3,119	4,070	4,322
ζ_0	0,409	0,220	0,068	0,117	0,380	0,803	0,912
ξ_0	0,035	0,027	-0,005	0,001	0,030	0,088	0,100
η_0	0,101	0,052	-0,002	0,016	0,105	0,182	0,196
ζ_1	0,196	0,141	-0,097	-0,041	0,196	0,421	0,463
ξ_1	0,056	0,014	0,038	0,041	0,055	0,070	0,077
η_1	0,065	0,018	0,038	0,043	0,065	0,086	0,091
ρ	0,901	0,021	0,860	0,867	0,901	0,936	0,943
$\sigma_{i,0}^2$	0,034	0,006	0,024	0,026	0,033	0,043	0,046
$\sigma_{i,1}^2$	0,529	0,162	0,296	0,321	0,502	0,836	0,927
p_{00}^z	0,797	0,101	0,553	0,606	0,813	0,931	0,944
p_{11}^z	0,901	0,050	0,781	0,806	0,909	0,966	0,973
p_{00}^u	0,815	0,088	0,612	0,651	0,828	0,935	0,950
p_{11}^u	0,904	0,055	0,771	0,804	0,914	0,970	0,977
Likelihood -255,017				Marginale Likelihood -304,465			
Restringiertes Modell							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	3,105	0,382	2,345	2,477	3,101	3,733	3,847
β_0	1,043	0,227	0,601	0,666	1,045	1,412	1,484
β_1	0,124	0,254	-0,374	-0,291	0,120	0,539	0,618
$\sigma_{\Delta y}^2$	2,998	0,453	2,262	2,346	2,948	3,815	3,995
ζ_0	0,335	0,206	-0,056	0,005	0,333	0,680	0,757
ξ_0	0,081	0,015	0,051	0,057	0,082	0,104	0,108
η_0	0,043	0,019	0,006	0,012	0,043	0,074	0,079
ζ_1	0,222	0,111	0,008	0,041	0,223	0,406	0,442
ξ_1	0,035	0,009	0,018	0,021	0,035	0,049	0,052
η_1	0,044	0,021	0,002	0,009	0,045	0,078	0,085
ρ	0,925	0,021	0,884	0,890	0,925	0,961	0,967
$\sigma_{i,0}^2$	0,032	0,006	0,023	0,024	0,031	0,042	0,044
$\sigma_{i,1}^2$	0,459	0,109	0,295	0,313	0,442	0,660	0,719
p_{00}^z	0,821	0,076	0,646	0,679	0,831	0,927	0,939
p_{11}^z	0,859	0,057	0,726	0,752	0,867	0,938	0,948
p_{00}^u	0,973	0,019	0,924	0,936	0,977	0,995	0,997
Likelihood -253,596				Marginale Likelihood -306,832			

A posteriori Verteilungen ermittelt per Gibbs-Sampling.

Tabelle 5.6: Gemeinsames Markov-Switching-Modell – USA – Teil (b)

Unrestringiertes Modell							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	2,932	0,270	2,424	2,497	2,931	3,365	3,441
β_0	0,937	0,199	0,566	0,616	0,932	1,267	1,341
β_1	0,130	0,123	-0,106	-0,065	0,126	0,329	0,369
$\sigma_{\Delta y,0}^2$	5,621	1,403	3,532	3,765	5,406	8,204	8,966
$\sigma_{\Delta y,1}^2$	0,469	0,116	0,289	0,312	0,454	0,676	0,731
p_{00}^w	0,894	0,053	0,767	0,798	0,903	0,962	0,970
p_{11}^w	0,880	0,058	0,743	0,771	0,889	0,959	0,966
ζ_0	0,315	0,142	0,062	0,099	0,307	0,552	0,609
ξ_0	0,030	0,023	-0,004	0,001	0,026	0,078	0,087
η_0	0,072	0,032	0,021	0,028	0,068	0,129	0,144
ζ_1	0,107	0,124	-0,140	-0,103	0,107	0,312	0,356
ξ_1	0,059	0,013	0,037	0,041	0,058	0,081	0,091
η_1	0,062	0,017	0,024	0,034	0,063	0,088	0,093
ρ	0,913	0,020	0,875	0,881	0,913	0,946	0,952
$\sigma_{i,0}^2$	0,034	0,008	0,024	0,025	0,033	0,044	0,046
$\sigma_{i,1}^2$	0,514	0,146	0,303	0,327	0,488	0,788	0,871
p_{00}^z	0,800	0,092	0,588	0,626	0,813	0,925	0,940
p_{11}^z	0,888	0,052	0,765	0,792	0,895	0,957	0,965
p_{00}^u	0,864	0,065	0,709	0,739	0,875	0,950	0,960
p_{11}^u	0,882	0,056	0,751	0,779	0,890	0,958	0,966
Likelihood -241,123			Marginale Likelihood -293,033				
Restringiertes Modell							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	3,673	0,232	3,207	3,286	3,675	4,046	4,122
β_0	0,959	0,201	0,615	0,660	0,944	1,309	1,374
β_1	-0,073	0,107	-0,278	-0,245	-0,074	0,103	0,146
$\sigma_{\Delta y,0}^2$	5,973	1,632	3,665	3,904	5,677	9,069	9,958
$\sigma_{\Delta y,1}^2$	0,576	0,136	0,366	0,390	0,560	0,812	0,882
p_{00}^w	0,892	0,051	0,772	0,799	0,900	0,958	0,966
p_{11}^w	0,864	0,066	0,708	0,740	0,873	0,954	0,964
ζ_0	0,349	0,205	-0,035	0,022	0,344	0,690	0,767
ξ_0	0,083	0,015	0,052	0,057	0,083	0,105	0,110
η_0	0,041	0,019	0,003	0,009	0,041	0,071	0,077
ζ_1	0,208	0,113	-0,022	0,018	0,209	0,393	0,427
ξ_1	0,034	0,009	0,017	0,020	0,034	0,049	0,052
η_1	0,046	0,020	0,006	0,012	0,047	0,079	0,085
ρ	0,926	0,022	0,886	0,892	0,926	0,964	0,971
$\sigma_{i,0}^2$	0,032	0,006	0,023	0,024	0,031	0,042	0,044
$\sigma_{i,1}^2$	0,457	0,109	0,294	0,313	0,440	0,659	0,718
p_{00}^z	0,823	0,077	0,646	0,681	0,834	0,929	0,941
p_{11}^z	0,861	0,058	0,721	0,752	0,870	0,940	0,950
p_{00}^u	0,974	0,018	0,929	0,939	0,978	0,995	0,997
Likelihood -240,731			Marginale Likelihood -295,469				

A posteriori Verteilungen ermittelt per Gibbs-Sampling.

Abbildung 5.12: Gemeinsames restringiertes Markov-Switching-Modell – USA – Teil (a)




Abbildung 5.13: Gemeinsames Markov-Switching-Modell – USA – Teil (b)





Abbildung 5.14: Gemeinsames restringiertes Markov-Switching-Modell – USA – Teil (b)



die richtige Richtung im Sinne des Modells von Estrella (2005) haben. In Zustand 0 ist ξ kleiner als im Zustand 1, während für β genau das Gegenteil gilt, vgl. Tabelle 5.5.

Im restringierten Modell wird für die gemeinsame Mittelwertgleichung ein Bruch unterstellt. Für Angaben zu den a posteriori Verteilungen der Parameter dieses Modells siehe ebenfalls Tabelle 5.5. Die a posteriori Verteilungen der Parameter μ , β_0 und β_1 für das gemeinsame Modell sind den a posteriori Verteilungen für das alleinige Modell der Vorlaufeigenschaften sehr ähnlich. Der Bruch wird nahezu identisch ermittelt, vgl. Abbildung 5.12 links mit Abbildung 5.1 rechts. Im Fall des restringierten Modells richtet sich die Inferenz der Zustände nach den Vorlaufeigenschaften und im unrestringierten Fall eher nach der Geldpolitik. Vergleicht man die Abbildungen 5.1 links, 5.9 und 5.11 links zeigen sich um 1984 und 1994 ähnliche Bewegungen in der Geldpolitik wie in den Vorlaufeigenschaften der Zinsdifferenz. Die Dominanz der Vorlaufeigenschaften in der Inferenz über die Zustände im restringierten Modell zeigt sich insbesondere darin, dass sich die Richtung der Änderungen der von ξ und η umgekehrt haben. Während ξ im unrestringierten Modell in Zustand 0 kleiner ist als in Zustand 1, ist dies im restringierten Modell umgekehrt, so dass die Schätzergebnisse des gemeinsamen Markov-Switching-Modells in Widerspruch zum Modell von Estrella (2005) treten.³² Die Schätzung des gemeinsamen Markov-Switching-Modells in der restringierten Form alleine liefert bereits ein Argument gegen die mit dem Modell von Estrella (2005) verbundene Hypothese, dass die Parameter der Geldpolitik und die Vorlaufeigenschaften die gleiche Zustandsabhängigkeit haben. Es wird jedoch mit Blick auf die Marginale Likelihood dem unrestringierten Fall des gemeinsamen Markov-Switching-Modells nicht vorgezogen.

³²Diese Relation zwischen den Parameterschätzungen der Markov-Switching-Spezifikationen bleibt auch im heteroskedastischen Fall erhalten.

Tabelle 5.7: Marginale Likelihood – Modellevidenz

	USA		Deutschland	
	homosked.	heterosked.	homosked.	heterosked.
Gemeinsames MS	-304,465	-293,033	-309,140	-301,354
Gemein. MS res.	-306,832	-295,469	-317,122	-305,350
Zwei MS	-304,073 -74,184/-229,889	-290,800 -74,184/-216,616	-308,628 -78,192/-230,436	-296,067 -78,192/-217,875
Zwei MS (res.)	-303,243 -74,184/-229,059	-289,340 -74,184/-215,156	-308,781 -78,192/-230,598	-295,836 -78,192/-217,644

In Tabelle 5.6 werden Ergebnisse dargestellt, die sich auf die heteroskedastische Modellierung der Vorlaufeigenschaften beziehen ($\sigma_{\Delta y,0}^2 \neq \sigma_{\Delta y,1}^2$). Die Abbildungen 5.13 und 5.14 beziehen sich auf diese Modelle. Auf der rechten Seite sind jeweils die entsprechenden Wahrscheinlichkeiten der Zustände der Varianz $\sigma_{\Delta y,w_t}^2$ dargestellt. Die Inferenz zu den Varianzzuständen in der Geldpolitikgleichung ist nahezu identisch, so dass diese hier nicht mehr gesondert dargestellt werden. Qualitativ entsprechen die Aussagen im heteroskedastischen Modell denen des homoskedastischen Modells. Die Inferenz über den Zustand der Mittelwertgleichung im unrestringierten Fall hat sich augenscheinlich den Ergebnissen für die Vorlaufeigenschaften angenähert, vgl. Abbildung 5.3 links und Abbildung 5.13 links.


Schließlich sind in Tabelle 5.7 die logarithmierten Werte der Marginalen Likelihoods auf einem Blick zusammengefasst. Es findet sich in keinem Fall Evidenz für das gemeinsame Markov-Switching-Modell. Immerhin kann im homoskedastischen Fall nur schwache Evidenz für das höher parametrisierte Modell gefunden werden.³³ Im heteroskedastischen Fall, der durchweg höhere Werte der Marginalen Likelihood aufweist, ist starke Evidenz gegen die Hypothese der gemeinsamen Zustandsabhängigkeit zu finden. Für die USA können die Daten die Hypothese einer gemeinsamen Zustandsabhängigkeit von Vorlaufeigenschaften der Zinsdifferenz und Geldpolitik trotz der augenscheinlichen Korrelation der Zustände nicht bestätigen.

Ergebnisse für Deutschland

Die a posteriori Verteilungen der Parameter des gemeinsamen Markov-Switching Modells aus Gleichung 5.12 für deutsche Daten sind im Fall der homoskedastischen Fehlervarianz in Tabelle 5.8 dargestellt. Die Verteilung von β_1 weist erhebliche Abweichungen von der für das alleinige Modell der Vorlaufeigenschaften ermittelten auf, sofern das unrestringierte Modell betrachtet wird. So ist der Mittelwert der Verteilung des gemeinsamen Modells nicht im zentralen 90% Intervall der a posteriori Verteilung von β_1 aus dem Modell der Gleichung 5.5, vgl. Tabelle 5.3.

³³Die Differenz beträgt 1,222 (-303,243+304,465). Nach Jeffreys (1961) entspricht dies schwacher Evidenz.

Abbildung 5.15: Gemeinsames Markov-Switching-Modell – Deutschland – Teil (a)



Dem entspricht das Bild der Inferenz der Zustände, Abbildung 5.15 links, das augenscheinlich von der Inferenz des alleinigen MS-Modells der Vorlaufeigenschaften abweicht, vgl. Abbildung 5.5 links. Im Gegenzug zeigen sich Ähnlichkeiten mit dem alleinigen MS-Modell der Geldpolitik, vgl. Abbildung 5.10. Die Inferenz über die Zustände wird also im wesentlichen durch die Geldpolitikgleichung bestimmt.

Für das gemeinsame restringierte MS-Modell ergeben sich ähnliche Werte für die Verteilungen der Parameter α , β_0 und β_1 wie für das alleinige restringierte MS-Modell der Vorlaufeigenschaften, vgl. Tabellen 5.3 und 5.8. Die Verteilung der Zustände zeigt große Ähnlichkeiten mit dem des restringierten MS-Modell der Vorlaufeigenschaften, vgl. Abbildung 5.5 rechts und 5.15. Die Konzentration des Übergangs um 1993 ist jedoch noch stärker ausgeprägt, was damit zu erklären ist, dass in dieser Zeit im unrestringierten Modell der Geldpolitik ebenfalls ein Regimewechsel angezeigt wird. Auch in Deutschland findet sich also eine Koinzidenz zwischen Veränderungen der Geldpolitik und der Zeitvariation der Vorlaufeigenschaften der Zinsdifferenz. Die Modellevidenz für das gemeinsame restringierte Markov-Switching-Modell im Vergleich zum unrestringierten spricht klar gegen den einzelnen Bruch, sondern für wiederkehrende Regime, was, wie noch gezeigt wird, für das Modell von Estrella (2005) spricht.

Das Verhältnis zwischen den Parametern ξ und β insbesondere im Hinblick auf die Frage unrestringiertes oder restringiertes Markov-Switching-Modell liefert eine Analogie zu den Ergebnissen der USA. Auch hier gilt im unrestringierten Fall, dass ξ im Zustand 0 kleiner ist als im Zustand 1, während für β das Gegenteil zutrifft. Im Widerspruch zum Modell von Estrella (2005) ist das restringierte Modell, in dem sich ξ und β beim Zustandswechsel in die gleiche Richtung verändern, wobei jedoch die Veränderung von ξ sehr gering ist.³⁴

³⁴Diese Ergebnisse bestätigen sich auch bei Berücksichtigung von Heteroskedastie

Tabelle 5.8: Gemeinsames Markov-Switching-Modell – Deutschland – Teil (a)

Unrestringiertes Modell							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	1,871	0,301	1,287	1,378	1,872	2,369	2,465
β_0	1,134	0,296	0,581	0,661	1,125	1,630	1,738
β_1	0,306	0,159	-0,004	0,046	0,306	0,568	0,622
$\sigma_{\Delta y}^2$	3,061	0,433	2,341	2,431	3,015	3,840	4,002
ζ_0	0,999	0,358	0,174	0,293	1,053	1,504	1,592
ξ_0	0,015	0,037	-0,093	-0,056	0,021	0,055	0,061
η_0	0,050	0,044	-0,023	-0,011	0,046	0,128	0,154
ζ_1	0,409	0,140	0,114	0,160	0,418	0,621	0,664
ξ_1	0,063	0,016	0,034	0,038	0,062	0,090	0,096
η_1	0,034	0,018	-0,003	0,004	0,034	0,064	0,070
ρ	0,844	0,042	0,769	0,781	0,840	0,920	0,934
σ_i^2	0,103	0,015	0,076	0,080	0,102	0,129	0,137
p_{00}^u	0,882	0,061	0,731	0,765	0,892	0,959	0,967
p_{11}^u	0,946	0,029	0,880	0,895	0,951	0,982	0,986
Likelihood -260,512			Marginale Likelihood -309,140				
Restringiertes Modell							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	1,653	0,208	1,235	1,304	1,656	1,988	2,048
β_0	0,693	0,119	0,467	0,501	0,692	0,888	0,929
β_1	0,009	0,208	-0,343	-0,304	-0,009	0,387	0,453
$\sigma_{\Delta y}^2$	2,903	0,407	2,216	2,311	2,867	3,635	3,819
ζ_0	0,436	0,161	0,072	0,141	0,449	0,679	0,716
ξ_0	0,074	0,017	0,047	0,051	0,071	0,109	0,119
η_0	0,039	0,021	-0,003	0,005	0,039	0,073	0,079
ζ_1	0,248	0,119	0,017	0,055	0,247	0,445	0,481
ξ_1	0,059	0,027	0,009	0,017	0,057	0,105	0,114
η_1	0,025	0,040	-0,057	-0,042	0,027	0,089	0,101
ρ	0,884	0,030	0,827	0,836	0,883	0,935	0,944
σ_i^2	0,148	0,020	0,114	0,119	0,146	0,182	0,190
p_{00}^u	0,953	0,034	0,869	0,887	0,962	0,992	0,995
Likelihood -268.446			Marginale Likelihood -317.122				

A posteriori Verteilungen ermittelt per Gibbs-Sampling.

Tabelle 5.9: Gemeinsames Markov-Switching-Modell – Deutschland – Teil (b)

Unrestringiertes Modell							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	1,394	0,284	0,879	0,951	1,381	1,879	1,969
β_0	1,096	0,252	0,661	0,716	1,077	1,528	1,641
β_1	0,424	0,176	0,036	0,110	0,434	0,691	0,731
$\sigma_{\Delta y,0}^2$	1,546	0,282	1,055	1,124	1,528	2,043	2,154
$\sigma_{\Delta y,1}^2$	12,338	4,605	6,358	6,938	11,388	20,755	24,020
p_{00}^w	0,948	0,034	0,863	0,885	0,955	0,987	0,990
p_{11}^w	0,760	0,103	0,533	0,572	0,772	0,910	0,927
ζ_0	0,704	0,426	0,011	0,089	0,669	1,400	1,503
ξ_0	0,008	0,052	-0,134	-0,104	0,018	0,082	0,091
η_0	0,064	0,046	-0,015	-0,002	0,059	0,149	0,170
ζ_1	0,319	0,175	-0,008	0,046	0,317	0,596	0,650
ξ_1	0,058	0,044	-0,094	-0,047	0,066	0,099	0,106
η_1	0,036	0,031	-0,010	-0,002	0,032	0,081	0,122
ρ	0,872	0,047	0,775	0,791	0,876	0,942	0,952
σ_i^2	0,109	0,019	0,077	0,081	0,107	0,142	0,150
p_{00}^u	0,873	0,069	0,704	0,742	0,885	0,960	0,969
p_{11}^u	0,930	0,049	0,793	0,837	0,941	0,980	0,984
Likelihood -251,609				Marginale Likelihood -301,354			
Restringiertes Modell							
	Mittelwert	Std.	2,5 %	5 %	50 %	95 %	97,5 %
μ	1,303	0,175	0,961	1,018	1,302	1,590	1,644
β_0	0,809	0,086	0,638	0,667	0,810	0,950	0,978
β_1	0,095	0,138	-0,179	-0,130	0,095	0,321	0,363
$\sigma_{\Delta y,0}^2$	1,338	0,231	0,930	0,988	1,322	1,751	1,843
$\sigma_{\Delta y,1}^2$	12,728	4,582	6,668	7,271	11,783	21,344	24,349
p_w^{00}	0,949	0,032	0,871	0,888	0,955	0,987	0,990
p_w^{11}	0,749	0,102	0,524	0,566	0,758	0,898	0,917
ζ_0	0,463	0,131	0,202	0,245	0,464	0,674	0,717
ξ_0	0,069	0,012	0,046	0,050	0,069	0,088	0,092
η_0	0,038	0,019	0,000	0,007	0,038	0,070	0,076
ζ_1	0,245	0,119	0,011	0,046	0,245	0,438	0,478
ξ_1	0,060	0,026	0,007	0,017	0,059	0,103	0,111
η_1	0,023	0,039	-0,053	-0,041	0,023	0,087	0,100
ρ	0,881	0,027	0,828	0,838	0,881	0,925	0,932
σ_i^2	0,148	0,020	0,114	0,119	0,147	0,183	0,191
p_{00}^u	0,957	0,030	0,882	0,900	0,963	0,992	0,994
Likelihood -252,333				Marginale Likelihood -305,350			

A posteriori Verteilungen ermittelt per Gibbs-Sampling.

Abbildung 5.16: Gemeinsames Markov-Switching-Modell – Deutschland – Teil (b)





Abbildung 5.17: Gemeinsames restringiertes Markov-Switching-Modell – Deutschland – Teil (b)



Durch die zusätzliche Berücksichtigung der Heteroskedastie in der Gleichung der Vorlaufeigenschaften werden die Ergebnisse qualitativ wenig verändert, vgl. die Tabellen 5.8 und 5.9. Die Inferenz über die Zustände ist augenscheinlich wie im homoskedastischen Fall, vgl. Abbildung 5.15 links mit Abbildung 5.16 links sowie Abbildung 5.15 rechts mit Abbildung 5.17 links. In Tabelle 5.4 sind die a posteriori Verteilungen der Parameter des Modells angegeben. Im unrestringierten Modell treten wiederum Abweichungen (allerdings schwächere) zwischen den a posteriori Verteilungen von β_1 des gemeinsamen MS-Modells und des MS-Modells, das sich ausschließlich auf die Vorlaufeigenschaften bezieht, auf. Für das restringierte MS-Modell entsprechen sich die a posteriori Verteilungen des gemeinsamen und des getrennten Modells im Wesentlichen. Bei Berücksichtigung der Heteroskedastie, die entsprechend der Marginalen Likelihood dem homoskedastischen Modell vorgezogen wird, sinkt die Evidenz für das unrestringierte Modell in Form der Differenz der logarithmierten Marginalen Likelihood. Das unrestringierte Modell wird aber noch klar vorgezogen (-305,350 restringiert zu -301,354 unrestringiert).

Die Inferenz über die Zustände der Varianz sind in allen Modellen nahezu identisch, ob restringiert, unrestringiert, gemeinsames oder getrenntes Modell, vgl. die Abbildungen 5.7 rechts, 5.8 rechts, 5.16 rechts und 5.17 rechts. Ähnliche Übereinstimmungen gelten auch für die Verteilungen der Übergangparameter.

Zusammenfassend findet sich bei der Betrachtung der Modellevidenz gegeben die deutschen Daten wiederum keine Evidenz für ein gemeinsames MS-Modell. Bei homoskedastischen Fehlern findet sich zwar nur sehr schwache Evidenz für das höher parametrisierte Modell mit getrennten Markov-Switching-Prozessen, vgl. Tabelle 5.7. Es bleibt jedoch zu bedenken, dass in diesem Fall Evidenz für die Zeitvariation weder der Vorlaufeigenschaften noch der Geldpolitik existiert. Also für beide, Geldpolitik und Vorlaufeigenschaften, von Stabilität auszugehen ist. Allerdings werden die Modelle mit heteroskedastischen Fehlern und Zeitvariation in den Vorlaufeigenschaften vorgezogen und hier findet sich starke Evidenz gegen das gemeinsame Markov-Switching-Modell, so dass eine Determination der Vorlaufeigenschaften der Zinsdifferenz durch die Geldpolitik auch in Deutschland nicht durch die Daten bestätigt werden kann.

5.3.5 Schluss

Die Diskussion über die Ursachen des Vorlaufverhaltens der Zinsdifferenz führt zu der Hypothese, dass die Geldpolitik die Vorlaufeigenschaften der Zinsdifferenz determiniert. Der Hypothese entsprechend sollte die Zeitvariation des Vorlaufverhaltens ihre Entsprechung in Änderungen der Geldpolitik finden.

In Abschnitt 5.2 wurde gezeigt, dass Evidenz für zeitvariierendes Vorlaufverhalten der Zinsdifferenz existent ist, wobei in den USA wie auch in Deutschland nicht eindeutig ist, ob die Zeitvariation als einzelner Bruch oder als wiederkehrende Regime zu charakterisieren ist. In Abschnitt 5.3.3 wurde ein Markov-Switching-Modell für die Geldpolitik eingeführt, das dann um das

die Zinsdifferenz verwendende Vorhersagemodell erweitert wurde. In keinem der besprochenen Fälle zeigte sich Evidenz für das gemeinsame Modell. Die Alternative, in der für die Geldpolitik und das Vorlaufverhalten getrennte Zustandsvariablen unterstellt werden, also keine direkte Abhängigkeit zwischen Geldpolitik und Vorlaufeigenschaften der Zinsdifferenz modelliert wird, wird favorisiert. Einzelne Episoden, in denen Veränderungen der Geldpolitik mit Veränderungen des Vorlaufverhaltens parallel laufen, führen nicht zu einer hinreichenden Gemeinsamkeit, die zu einer Evidenz im Sinne von Jeffreys' Skala führt. Die Hypothese, die im Modell von Estrella (2005) Gestalt angenommen hat, wird also hier verworfen. Andere Ursachen der Zeitvariation der Vorlaufeigenschaften der Zinsdifferenz wie zeitvariierende Risikoprämien sollten in Betracht gezogen werden.³⁵ Die bisherigen Modelle reichen nicht aus die Instabilitäten des Vorlaufverhaltens der Zinsdifferenz zu erklären. Trotz einiger Erklärungsansätze durch die ökonomische Theorie ist die Zinsdifferenz im Hinblick auf ihre ökonomische Signifikanz und Stabilität als Frühindikator mit der nötigen Vorsicht zu betrachten.

³⁵Siehe dazu Hamilton und Kim (2002) oder Ang et al. (2006).

Kapitel 6

Echtzeitdaten und die Vorhersage von Datenrevisionen

In der bisherigen Arbeit wurden die Eigenschaften der Daten des BIP nicht diskutiert und die Daten als endgültig angenommen, das heißt, dass die Daten exakt das repräsentieren, was sie messen sollen. In der Regel werden jedoch makroökonomische Variablen nicht direkt im Moment der Entstehung beobachtet. Eine Ausnahme bilden Zinsen und Preise, die sofort bei der Entstehung zumindest den Marktteilnehmern bekannt sind.¹ Für viele andere Größen gilt, dass es sich um Aggregate handelt, deren Umfang von vielen Agenten beeinflusst wird. Eine vollständige und sofortige Erfassung erscheint selbst beim heutigen Stand der Informationstechnik nicht verhältnismäßig.

Im Rahmen der Volkswirtschaftlichen Gesamtrechnung (VGR) in Deutschland werden Statistiken der Unternehmen in verschiedener Frequenz und von verschiedenen großen Stichproben erhoben. Wegen des Aufwands der Datenerhebung gibt es ein Spannungsverhältnis zwischen Zeitnähe der Veröffentlichungen und der Qualität.² Aufwendigere und qualitativ hochwertigere Erhebungen werden entsprechend in einer geringeren Frequenz durchgeführt. Die unterjährig (monatlich oder quartalsweise) erhobenen Daten stammen nur von einem Bruchteil der Unternehmen. Jährliche Erhebungen, die alle Unternehmen mit mehr als 20 Beschäftigten erfassen, dienen dann dazu die zuvor ermittelten Daten zu revidieren. Außerdem fließen weitere Statistiken, wie die Umsatzsteuerstatistik, in den fortlaufenden Prozess der Erstellung der VGR und somit der BIP-Zahlen ein.³ Vor diesem Hintergrund erscheint es plausibel, dass BIP-Zahlen immer wieder Veränderungen unterliegen und erste Veröffentlichungen vorläufigen Charakter haben. In diesem Zusammenhang wird der Terminus “Echtzeitdaten” verwendet. Die Bedeutung

¹Was für Preise gilt, gilt nicht für Preisniveaus, die wiederum von Umsatzmengen und im Rahmen hedonistischer Preisindizes auch von Qualitätsmerkmalen abhängen.

²Vgl. Statistisches Bundesamt (2007).

³Vgl. Statistisches Bundesamt (2002).

von Echtzeitdaten in der Politikberatung bzw. ihr Einfluss auf die Ergebnisse von Prognosen und ökonometrischen Modellen hat in den letzten Jahren eine große Aufmerksamkeit erhalten.⁴ Dabei geht es um die Frage, ob die geringe Qualität der Daten am aktuellen Rand Einfluss auf die Politik nimmt bzw. zu falschen Politikempfehlungen zum Beispiel für die Geldpolitik führt. In der Geldpolitik wird im besonderen Maße auf aktuelle Informationen über Inflation und BIP-Wachstum geachtet, so dass hier die Datenqualität am aktuellen Rand von besonderem Interesse ist.⁵

Drei Aspekte, die BIP-Daten betreffen, werden im Folgenden eine Rolle spielen. Zum einen der zeitliche Unterschied zwischen Entstehung und Bericht der BIP-Daten, der zu einer relativ breiten Literatur zum Thema “Nowcasting” geführt hat.⁶ Zweitens spielen verschiedene Frequenzen in denen makroökonomische Daten verfügbar sind eine Rolle. Zinssätze zum Beispiel sind nahezu in beliebig hoher Frequenz beobachtbar. Die Industrieproduktion wird für Deutschland oder die USA monatlich ausgewiesen, das BIP nur quartalsweise. Wegen der niedrigen Erhebungsfrequenz und Problemen der zeitlichen Abgrenzung erscheint es allerdings sinnvoll, dass das BIP in einer relativ niedrigen Frequenz berichtet wird. Drittens geht es um die Revisionen der BIP-Daten. Das zuvor erwähnte Spannungsverhältnis zwischen dem Wunsch zeitnaher Informationen und der durch die Kosten intensiverer Erhebungen bedingten anfangs geringeren Validität wird in der Regel so gehandhabt, dass erste Schätzungen des BIP im Folgequartal bekannt gegeben werden und diese in der späteren Zeit entsprechend der sich mit der Zeit verbessernden Informationslage revidiert werden. Insbesondere die Frage, ob Revisionen eine Systematik inne wohnt, die zur Verbesserung der frühen Datenbekanntgaben genutzt werden können, ist Gegenstand dieses Abschnitts. Die ersten beiden genannten Aspekte sind hierzu aus methodischer Sicht von Interesse.

6.1 Echtzeitdaten und Datenrationalität

Mankiw und Shapiro (1986) argumentieren mit zwei alternativen Erklärungsansätzen für Datenrevisionen des BIP. Zum einen können Datenrevisionen als Berichtigung von Mess- oder Berichtsfehlern (operationale Fehler, “noise”) angesehen werden und zum anderen auf das Eintreffen neuer Informationen (“news”) zurückgeführt werden, da zum Beispiel größere Stichproben von Unternehmensdaten oder andere Erhebungen zugänglich geworden sind, wie am Beispiel der

⁴Bernanke und Boivin (2003) analysieren die Geldpolitik in den USA mit Echtzeitdaten und Gerberding et al. (2005) die Geldpolitik der Bundesbank. Croushore und Stark (2003) überprüfen den Einfluss von Echtzeitdaten auf die Ergebnisse einer Vielzahl makroökonomischer Modelle. Vorhersagemodelle mit Echtzeit-Daten werden unter anderem in Breitung und Schumacher (2006) und Croushore (2006) diskutiert.

⁵Bereits Mankiw et al. (1984), die Revisionen von Geldmengendaten betrachten, fordern angesichts der Vorhersagbarkeit der Revisionen nicht die frühen Veröffentlichungen der Daten zur Politikberatung, sondern modellbasierte Vorhersagen zu verwenden.

⁶Siehe z.B. Giannone et al. (2005), Mitchell et al. (2005), Nunes (2005) oder Evans (2005).

deutschen VGR bereits erläutert. Operationale Fehler oder “noise” können einfache Tippfehler sein aber auch eher systematische Fehler, wie die Anwendung falscher Hochrechnungsfaktoren bei den weniger umfangreichen unterjährigsten Statistiken. Sofern Datenrevisionen auf operationale Fehler zurückzuführen sind, sollten diese prognostizierbar sein, da die Informationen, die den “wahren” Werten entsprechen, zum Zeitpunkt der Veröffentlichung verfügbar sind.

Über zwei einfache Gleichungen lässt sich testen, ob die eine bzw. die andere Hypothese über das Verhalten der datenberichtenden Agentur zutreffend ist:

$${}_{t+1+k}y_t = \alpha^{(1)} + \beta^{(1)} {}_{t+1}y_t + e_t^{(1)} \quad (6.1)$$

und

$${}_{t+1}y_t = \alpha^{(2)} + \beta^{(2)} {}_{t+1+k}y_t + e_t^{(2)}, \quad (6.2)$$

wobei y_t die von der datenberichtenden Agentur bereitgestellte makroökonomische Variable zum Zeitpunkt t bezeichnet und der vorgestellte Index den Zeitpunkt der Veröffentlichung meint. Sofern Datenrevisionen auf unerwartete neue Informationen zurückzuführen sind, ist ${}_{t+1}y_t$ ein unverzerrter Schätzer von ${}_{t+1+k}y_t$, was der testbaren Parameterrestriktion $\alpha^{(1)} = 0$ und $\beta^{(1)} = 1$ entspricht. In diesem Fall wird von der Rationalität des datenberichtenden Prozesses gesprochen.⁷ Würden die Datenrevisionen ausschließlich unsystematischen operationalen Fehlern geschuldet sein, dann entspräche die Gleichung 6.1 dem Fehler-in-Variablen Problem und die Schätzer wären verzerrt. Ferner würde in Gleichung 6.2 die Parameterrestriktion $\alpha^{(2)} = 0$ und $\beta^{(2)} = 1$ gelten. In diesem Fall würden die frühen Veröffentlichungen mit den Revisionen korrelieren. Carstensen und Liedo (2005) finden für deutsche BSP-Daten und US BIP-Daten, dass die statistische Annahme der Hypothese $\alpha^{(1)} = 0$ und $\beta^{(1)} = 1$ nur in wenigen Fällen mit dem Verwerfen der Hypothese $\alpha^{(2)} = 0$ und $\beta^{(2)} = 1$ einhergeht. Die “news” und “noise” Hypothese scheinen sich nicht perfekt auszuschließen. Im Folgenden wird daher die Analyse auf die Frage begrenzt, ob bzw. wie Datenrevisionen bestmöglich vorhersagbar sind. Die Vorhersagemodelle dienen also dem Ziel eventuell verbesserte Daten am aktuellen Rand zu gewährleisten.

Mankiw und Shapiro (1986) können für BSP-Wachstumsraten der USA die Hypothese der Datenrationalität nicht verwerfen. Auch Faust et al. (2005) finden für die USA wenig Evidenz, dass Revisionen des BIP-Wachstums prognostizierbar sind.⁸ Im Gegensatz zu Mankiw und Shapiro (1986) verwenden Faust et al. (2005) bei der Überprüfung der Datenrationalität nicht nur das Modell in Gleichung 6.1, sondern erlauben noch weitere Regressoren. Ferner wird als Abhängige nicht das “wahre” BIP-Wachstum bzw. hinreichend revidierte BIP-Wachstum genommen, sondern die Revision:

$${}_{t+1+k}rev_t = {}_{t+1+k}y_t - {}_{t+1}y_t = \alpha + \tilde{\beta} {}_{t+1}y_t + X_{t+1}'\gamma + e_t, \quad (6.3)$$

⁷Mankiw et al. (1984) haben bei der Analyse von Veröffentlichungen und Revisionen der Geldmenge den Begriff der Datenrationalität in die Literatur eingeführt.

⁸Für andere G 7 Länder finden Faust et al. (2005) prognostizierbare Datenrevisionen, so auch für deutsche BIP-Daten.

wobei $\tilde{\beta}$ dem Ausdruck $\beta^{(1)} - 1$ aus Gleichung 6.1 entspricht und X_{t+1} weitere Regressoren darstellt, die zum Zeitpunkt der Datenveröffentlichung bekannt sind.

Fixler und Grimm (2006) finden mit einem ähnlichen Modell wie Faust et al. (2005) in einem Datensatz etwas anderen Zuschnitts Evidenz gegen die Datenrationalität des US BIP-Wachstums. Insbesondere berücksichtigen sie als Regressoren Vorhersagen des BIP-Wachstums und die Zinsdifferenz, die jeweils mit positivem Vorzeichen in die Regression der Revisionen eingehen, während für die zeitnahen Veröffentlichungen des BIP-Wachstums $_{t+1}y_t$ ein negatives Vorzeichen geschätzt wird. Golinelli und Parigi (2005) formulieren den Zusammenhang dahingehend, dass sich das wahre BIP-Wachstum als lineare Funktion der ersten Datenveröffentlichung und der Vorhersage des BIP-Wachstums ergibt. Dieser Ansatz von Golinelli und Parigi (2005) sowie Fixler und Grimm (2006) wird an dieser Stelle um den Aspekt erweitert, dass in den letzten Jahren eine breite Literatur unter dem Stichwort “Nowcasting” entstanden ist. Bei Vorhersagen finden Informationen Verwendung, die vor dem vorherzusagenden Zeitpunkt liegen, da es das Ziel ist vor diesem Zeitpunkt eine Aussage zu tätigen. Die Zeitspanne der Entstehung des BIP und die Zeit danach bis zur Veröffentlichung der ersten Schätzung durch die datenberichtende Agentur werden im Diskurs über die Höhe des BIP-Wachstums nicht berücksichtigt. “Nowcasting” schließt diese Lücke zwischen Vorhersage und ersten Datenveröffentlichungen indem andere Daten, die in dieser Zeit anfallen, die also in höherer Frequenz auftreten oder zeitnäher berichtet werden, dazu verwendet werden Prognosen über das BIP-Wachstum zu machen, das gerade stattfindet oder gerade stattgefunden hat.

Die Methoden, die beim “Nowcasting” zur Anwendung kommen und die darauf abzielen, Daten verschiedener Frequenz und Zeitnähe in ein Modell einzubinden, werden an dieser Stelle nicht direkt zur Inferenz über das BIP-Wachstum herangezogen, sondern zur Inferenz über dessen Revisionen. Die bestehenden Ansätze haben gezeigt, dass Variablen, die in Verbindung zur Konjunktur stehen, z.B. als Frühindikatoren, auch einen Beitrag zur Vorhersage und Erklärung von Revisionen bringen. Von diesen Variablen werden oft Beobachtungen gemacht, die bis direkt zum Veröffentlichungszeitpunkt des BIP reichen und bisher ungenutzt bleiben. Ausgehend von “Nowcasting”-Modellen und den bisherigen Ansätzen zur Vorhersage von Datenrevisionen schlägt diese Arbeit die Verwendung von “Backcasting”-Modellen zur Bestimmung des BIP am aktuellen Rand vor, die die ersten Veröffentlichungen des BIP berücksichtigen.⁹ Im Vergleich zu den bisherigen Arbeiten zur Vorhersage von Datenrevisionen werden in dieser Arbeit durch den gemischt frequenten Ansatz mehr Informationen zur Vorhersage genutzt, die auch tatsächlich im Augenblick der ersten Datenveröffentlichung verfügbar sind. Die bisherigen Ansätze vernachlässigen die jeweils aktuellsten Informationen schlicht aus methodischen Gründen. Im folgenden Abschnitt werden die Methoden erläutert, die es erlauben höherfrequente Regressoren zu berücksichtigen.

⁹Vorhersagemodelle für Datenrevisionen können als Backcastingmodelle für das “wahre” BIP-Wachstum angesehen werden.

gebracht.

$$y_t = \begin{pmatrix} w_1 & w_2 & w_3 & \dots \end{pmatrix} \begin{pmatrix} y_{m,t} \\ y_{m,t-1/3} \\ y_{m,t-2/3} \\ \vdots \end{pmatrix}$$

Die unbeobachtbaren Monatswerte folgen der Bewegungsgleichung, in der das lineare Modell in monatlicher Frequenz $x_t\beta$ berücksichtigt wird. An dieser Stelle wird der Quartalsindex t verwendet, wobei auch monatliche Werte zwischen t und $t + 1$ auftreten, die mit $t + 1/3$ und $t + 2/3$ indiziert werden.

$$\begin{pmatrix} y_{m,t} \\ y_{m,t-1/3} \\ y_{m,t-2/3} \\ \vdots \end{pmatrix} = \begin{pmatrix} x_t\beta \\ 0 \\ 0 \\ \vdots \end{pmatrix} + \begin{pmatrix} 0 & 0 & \dots & 0 \\ 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & 0 \end{pmatrix} \begin{pmatrix} y_{m,t-1/3} \\ y_{m,t-2/3} \\ y_{m,t-1} \\ \vdots \end{pmatrix} + \begin{pmatrix} e_{m,t} \\ 0 \\ 0 \\ \vdots \end{pmatrix}, \quad e_{m,t} \sim N(0, \sigma_m^2).$$

6.2.3 MIDAS

Der Interpolationsansatz, auch in der Formulierung als Zustandsraummodell, nimmt einen linearen Zusammenhang in der höchsten Frequenz an, der über eine feste Gewichtung aggregiert wird. Alternativ dazu wird im MIDAS-Ansatz (MIxed DATA frequency Sampling) die Gewichtung selber parametrisiert und mit geschätzt, vgl. Ghysels et al. (2004). Der Ansatz hat seinen Ursprung in der Finanzmarktliteratur, in der mit ultra hoch frequenten Daten gearbeitet wird und die Aggregation nicht nur drei, wie zwischen Monats- und Quartalsdaten, sondern bedeutend mehr Zeitperioden umfassen kann.

Die grundlegende Gleichung des MIDAS-Modells lautet wie folgt:

$$y_t = \beta_0 + \beta_1 G(L^{1/h}; \theta) X_{t-1}^{(h)} + \varepsilon_t, \quad (6.10)$$

wobei $G(L^{1/h}; \theta) = \sum_{j=0}^J g(j, \theta) L^{j/h}$ und $L^{j/h} X_{t-1}^{(h)} = x_{t-1-j/h}$. Der Index t repräsentiert den Zeitindex der geringeren Frequenz. h gibt die Beziehung zwischen niedriger und hoher Frequenz an. Wenn y quartalsweise erhoben wird und x monatlich, dann ist $h = 3$. J repräsentiert die Zahl der (monatlichen) Verzögerten von X die im Modell berücksichtigt werden. Folglich stellt $X_{t-1}^{(h)}$ einen Vektor von zeitlich benachbarten Beobachtungen von X mit der Länge J dar. In der Regel ist J bedeutend größer als h . $g(j, \theta)$ ist die Gewichtungsfunktion. Ghysels et al. (2004) schlagen die folgende Form vor:

$$g(j, \theta) = \frac{\exp(\theta_1 j + \theta_2 j^2)}{\sum_{\tilde{j}=1}^J \exp(\theta_1 \tilde{j} + \theta_2 \tilde{j}^2)}. \quad (6.11)$$

Die Gewichtungsfunktion wird von zwei Parametern θ_1 und θ_2 gesteuert. Um das MIDAS-Modell für den hier relevanten Fall zu veranschaulichen, sei unterstellt, dass y quartalsweise erhoben wird und x monatlich ($h = 3$). Ferner werden die Werte von x des vergangenen Jahres ($J = 12$) als Regressoren berücksichtigt:

$$y_t = \beta_0 + \beta_1 [g(0, \theta)x_{t-1} + g(1, \theta)x_{t-1-1/3} + g(2, \theta)x_{t-1-2/3} + \dots + g(12, \theta)x_{t-5}] + \varepsilon_t. \quad (6.12)$$

Tatsächlich stellt die Interpolation einen Spezialfall des Modells in Gleichung 6.10 dar, wobei die Gewichtung nicht eine parametrisierte Form aus Gleichung 6.11 ist, sondern auf die feste Gewichtungsmatrix W zurückgeht.

6.3 Vorhersage von Datenrevisionen

In dieser Arbeit werden Datenrevisionen der Wachstumsraten des BIP bzw. des Bruttonationalprodukts (BSP) für die USA und Deutschland analysiert. Für die USA werden die Daten von der Federal Reserve Bank of Philadelphia verwendet.¹² Eine Vielzahl an Variablen ist über diese Quelle verfügbar. Der Datensatz wird am aktuellen Rand beständig fortgeschrieben. Für das BIP/BSP wird eine Variable "Realer Output" berichtet, die sich vor 1991 auf das BSP und danach auf das BIP bezieht. Da die wesentlichen Bestandteile identisch sind und durch die Betrachtung von Wachstumsraten Niveauunterschiede keine Rolle spielen, werden die Wachstumsraten des "Realen Outputs" als abhängige Variable verwendet. Pro Quartal wird die jeweils letzte Datenveröffentlichung berichtet. Veröffentlichungen innerhalb des Quartals, wie Vorabschätzungen, sind über diesen Datensatz nicht zugänglich.¹³ Ferner enthält der Echtzeitdatensatz der Federal Reserve Bank of Philadelphia einige monatliche und quartalsweise erhobene Variablen, die in Vorhersagemodellen berücksichtigt werden können.¹⁴ Von der OECD-Datenbank und der Datenbank FRED der Federal Reserve Bank of St. Louis werden weitere Variablen entnommen, die keinerlei Revisionen unterliegen, wie Zinsen oder das Verbrauchervertrauen. Die Analyse für die USA bezieht sich auf das BIP bzw. BSP zwischen 1985 und 2003. Wegen des starken Volatilitätsrückgangs in 1984 in den USA und daraus resultierenden möglichen Instabilitäten im Datenberichtsprozess werden nur Daten nach diesem Zeitpunkt berücksichtigt. Die Stichprobe endet in 2003 um eine hinreichende Revisionsgeschichte der letzten Datenpunkte zu gewährleisten.

¹²Download im Oktober 2006: <http://www.phil.frb.org/econ/forecast/readow.html>

¹³Über das Datenportal ALFRED der Federal Reserve Bank of St. Louis sind auch Vorabschätzungen innerhalb der Quartale verfügbar. Sie sind allerdings sehr volatil und teilweise unregelmäßig, was mit zusätzlichen methodischen Problemen bei der Formulierung von Vorhersagemodellen einherginge.

¹⁴Siehe Appendix A.8 für die Datenübersicht.

Für Deutschland stammen die Echtzeitdaten aus der Arbeit von Gerberding et al. (2005), die über die Bundesbank verfügbar sind. Im Gegensatz zu den Daten der USA werden diese allerdings nicht fortlaufend aktualisiert, sondern berücksichtigen als letzte bzw. jüngste Daten für das saisonbereinigte BSP die Veröffentlichung im August 1995. Ferner sind nur BIP bzw. BSP und der Konsumentenpreisindex berücksichtigt. Daher fehlen viele gleichlaufende Indikatoren der Konjunktur wie die Industrieproduktion oder die Kapazitätsauslastung als Regressoren in der Analyse deutscher Datenrevisionen. Als Regressoren bieten sich ausschließlich Variablen an, die keinen Revisionen unterliegen, sofern ein Vorhersagemodell (in Echtzeit) angestrebt wird. Von der OECD-Datenbank werden die Zinsdifferenz, der Aktienindex C-DAX (der in Form von Quartalsrenditen berücksichtigt wird), das Ifo-Konsumklima sowie Arbeitslosenzahlen herangezogen. Da die Revisionen des BSP-Wachstums für die Spanne von 1973 bis 1993 als Abhängige verwendet wird, fallen das GfK-Konsumklima oder der ZEW-Index aus, da sie zwar revisionsfreie Indikatoren sind, aber erst seit 1983 bzw. 1991 erhoben werden. Das westdeutsche BSP wird im Gegensatz zum BIP verwendet, da für das BSP ein umfangreicherer Datenbestand verfügbar ist.

6.3.1 Vorhersagemodelle

An dieser Stelle werden die Modelle vorgestellt, die zur Vorhersage der Datenrevisionen in der empirischen Analyse zur Anwendung kommen. Das Modell in Gleichung 6.3 dient dabei als Ausgangspunkt. Lineare Modelle dieser Art finden Anwendung in Faust et al. (2005) oder Fixler und Grimm (2006). Da hier nur Quartalsdaten bzw. zuvor entsprechend aggregierte Regressoren zur Anwendung kommen, ist es der Vergleichspunkt für die Hypothese, dass es sinnvoll ist mehr Informationen am aktuellen Rand in Form von monatlichen Regressoren aufzunehmen.

Basierend auf Gleichung 6.3 werden zwei Modelle berücksichtigt, die sich durch die Auswahl der Regressoren unterscheiden. In Modell *I* werden nur Informationen aus dem Revisionsprozess der Variablen selbst und saisonale Dummies als Regressoren berücksichtigt. In Modell *II* wird das vorhergehende Modell um Regressoren erweitert, die als Früh- und gleichlaufenden Indikatoren der Konjunktur gelten und die die Frequenz des BIP haben bzw. die in diese Frequenz vorab überführt worden sind, so dass die Regressormatrix X im Modell *II* eine erweiterte Form der Regressormatrix X des Modells *I* ist.

In Modell *III* werden die Regressoren, die zusätzlich zu denen in Modell *I* berücksichtigt werden und mindestens in monatlicher Frequenz vorliegen, als monatliche Regressoren Z im Rahmen eines Interpolationsmodells berücksichtigt. Modell *III* hat die folgende Form:

$${}_{t+1+k}rev_t = \alpha + \tilde{\beta} {}_{t+1}y_t + X_{t+1}'\gamma_1 + \tilde{W}'Z_{t+1}\gamma_2 + e_t, \quad (6.13)$$

wobei \tilde{W} den korrespondierenden Vektor aus der Gewichtungsmatrix in Gleichung 6.7 darstellt. Da das BIP eine Flussgröße ist und y_t die Wachstumsraten wiedergibt, wird an dieser Stelle die Matrix W aus Gleichung 6.7 verwendet.

Das Interpolationsverfahren unterstellt einen linearen Zusammenhang zwischen den Variablen in der höheren Frequenz, der über eine vorgegebene Aggregation bzw. Gewichtung mit den beobachtbaren Quartalsdaten in Verbindung gebracht wird. Im MIDAS-Ansatz wird die Gewichtung parametrisiert und das Modell in der niedrigeren Frequenz formuliert. Dieser wird in Modell *IV* eingesetzt um die Variablen, die bereits in Modell *III* genutzt werden, alternativ in die Revisionsvorhersagen einfließen zu lassen:

$${}_{t+1+k}rev_t = \alpha + \tilde{\beta} {}_{t+1}y_t + X_{t+1}'\gamma_1 + \gamma_2 G\left(L^{1/3}; \theta\right) Z_{t+1}^{(3)} + e_t. \quad (6.14)$$

Für die Modelle *III* und *IV*, wie auch für die Modelle *I* und *II*, werden die Regressoren über das adjustierte R^2 ausgewählt. Die bereits diskutierten Faktormodelle geben die Möglichkeit alle verfügbaren Variablen als bedingende Information einzusetzen ohne ein zu hoch parametrisiertes Modell zu erhalten. Aus den Variablen wird dabei eine Anzahl von Faktoren ermittelt, die weitaus geringer ist als die Anzahl der Variablen. Die bzw. der Faktor wird als Regressor im Modell verwendet. Im Modell *V* bilden die mit Faktormodellen gewonnenen Regressoren die monatlichen Regressoren Z der Gleichung 6.13. Im Modell *VI* werden die monatlichen Faktoren mit dem MIDAS-Ansatz eingebunden, vgl. Gleichung 6.14. Die folgende Darstellung fasst die verschiedenen Modelle auf einen Blick zusammen:

<i>I</i>	“Univariates” Modell (gleichfrequente Regressoren wie Zeitverzögerte oder Saisondummies)
<i>II</i>	Erweiterung von Modell <i>I</i> mit gleichfrequenten makroökonomischen Regressoren
<i>III</i>	Erweiterung von Modell <i>I</i> mit höher frequenten makroökonomischen Regressoren (Interpolation)
<i>IV</i>	Erweiterung von Modell <i>I</i> mit höher frequenten makroökonomischen Regressoren (MIDAS)
<i>V</i>	Erweiterung von Modell <i>I</i> mit monatlichen Faktoren als Regressoren (Interpolation)
<i>VI</i>	Erweiterung von Modell <i>I</i> mit monatlichen Faktoren als Regressoren (MIDAS)

Der hier eingeführte gemischt frequente Ansatz ist explizit für die Anwendung in Echtzeit am aktuellen Rand auf die Fragestellung hin konzipiert, ob höher frequente Informationen die Vorhersage von Datenrevisionen bzw. die Datenqualität der BIP-Veröffentlichungen verbessern können. Mit Fortschreiten der Zeit weitet sich der Informationsstand aus, so dass bereits einzelne Monate wichtige neue Informationen mit sich bringen können. Um genau diesem Umstand Rechnung zu tragen und die gemischt frequenten Vorhersagemodelle in dieser Hinsicht zu überprüfen werden sie in drei verschiedenen Informationssituationen angewendet. In der Situation *A* werden die Informationen berücksichtigt, die im Quartal der ersten Veröffentlichung ($t + 1$) des BIP-Wachstums des Quartals t bekannt sind. Sofern monatliche Daten angewendet werden, werden Daten bis $t + 1/3$ aufgenommen und bezogen auf Quartalsdaten bis einschließlich t . In der Situation *B* werden die folgenden zwei Monate zusätzlich berücksichtigt, um zu überprüfen, ob die Informationen, die zwischen den beiden ersten Datenveröffentlichungen des BIP liegen, noch Informationen für zukünftige Revisionen enthalten. Ferner soll dadurch ermöglicht werden, erste eventuelle Revisionen der monatlichen Regressoren, wie der Beschäftigung oder der Kapazitätsauslastung zu berücksichtigen. Schließlich wird eine dritte Situation berücksichtigt, die

im wesentlichen der Situation B entspricht, aber die erste Revision der BIP-Daten mitberücksichtigt. Entsprechend wird in C nicht ${}_{t+1+k}y_t - {}_{t+1}y_t$ sondern ${}_{t+1+k}y_t - {}_{t+2}y_t$ regressiert. Die Berücksichtigung dieses Informationsstandes dient zur Überprüfung der Frage, ob der unter A und B vorhersagbare Anteil der Revisionen bereits in der ersten Revision berücksichtigt wird und somit nach der ersten Revision, was der zweiten Veröffentlichung der BIP-Daten entspricht, das Vorhersagemodell obsolet wird. Die folgende Darstellung gibt alle drei Informationsstände wieder:


A	Informationsstand zum Zeitpunkt der ersten Veröffentlichung des BIP einen Monat nach Ende des Quartals. Abhängige: ${}_{t+1+k}y_t - {}_{t+1}y_t$.
B	Informationsstand am Ende des Folgequartals; es werden zwei weitere Monate monatliche Informationen hinzugenommen. Abhängige: ${}_{t+1+k}y_t - {}_{t+1}y_t$.
C	Informationsstand bei der Veröffentlichung der ersten Revision. Abhängige: ${}_{t+1+k}y_t - {}_{t+2}y_t$.

Die Modelle I bis VI werden also in drei Situationen A , B und C mit unterschiedlichen Informationsständen angepasst, wobei in den Modellen I und II die Informationssituation B nicht genutzt werden kann und somit für I und II kein Unterschied zwischen A und B besteht. Die unterschiedlichen Informationsstände korrespondieren mit unterschiedlichen Situationen am aktuellen Rand bezogen auf die relative zeitliche Position zu den Datenveröffentlichungen des BIP. Ziel der Modelle ist es Datenrevisionen zeitnah zur ersten Veröffentlichung vorherzusagen. Die Datenrevisionen beziehen sich auf die letzte verfügbare Datenveröffentlichung, im Folgenden Langzeitrevisionen. Ein methodisches Problem der Langzeitrevisionen besteht darin, dass die Revisionsdauer innerhalb der Stichprobe variiert bzw. abnimmt also in ${}_{t+1+k}y_t - {}_{t+1}y_t$ der Term $k = T_p - t$ ist, wobei T_p das Datum der letzten verfügbaren Datenveröffentlichung meint. Mit der Annahme, dass die meisten und bedeutendsten Revisionen des BIP-Wachstums in den ersten Jahren stattfinden, ist dieses Vorgehen zu rechtfertigen. Um in dieser Hinsicht Konsistenz der Stichprobe herzustellen, werden nur Daten zur Überprüfung der Langzeitrevisionen verwendet, die mindestens drei Jahre vor der zuletzt beachteten Datenveröffentlichung das erste Mal veröffentlicht worden sind, die also mindestens drei Jahren der Revision unterzogen waren. Angelehnt an Faust et al. (2005) werden alternativ Kurzzeitrevisionen als abhängige Variable verwendet. Kurzzeitrevisionen bezeichnen an dieser Stelle Revisionen mit einem festen Revisionshorizont von zwei Jahren bzw. mit $k = 8$. Die methodische Problematik der variierenden Revisionshorizonte wird entsprechend umgangen.

6.3.2 Datenrevisionen des realen Outputs der USA

In Abbildung 6.1 sind die Zeitreihe der ersten Veröffentlichungen des realen saisonbereinigten Wachstums des BIP der USA (${}_{t+1}y_t$), die dazugehörigen Revisionen nach zwei Jahren (${}_{t+1+8}y_t - {}_{t+1}y_t$) und wiederum ausgehend von den ersten Veröffentlichungen die gesamten Revisionen bis zur letzten Veröffentlichung (Stand Oktober 2006) abgetragen. Die folgenden Ergeb-

Abbildung 6.1: Datenrevisionen – USA



nisse der Vorhersagemodelle beziehen sich auf die Zeitreihe der letzten Revisionen bzw. Langzeitrevisionen und auf die Revisionen nach zwei Jahren bzw. Kurzzeitrevisionen. Das BIP-Wachstum entsprechend seiner ersten Veröffentlichungen hat eine Standardabweichung von 0,791. Werden die Revisionen nach zwei Jahren dazu gezählt, die im Mittel 0,033 betragen, erhält man eine Standardabweichung des BIP-Wachstums von 0,969, was für die Hypothese der Datenrationalität spricht, die entsprechend der ersten Veröffentlichungen weniger volatil sein sollten als die endgültigen. Durch die weiteren Revisionen sinkt die Volatilität allerdings etwas, so dass für die betrachteten Perioden die Standardabweichung des BIP-Wachstums mit Stand vom Oktober 2006 mit 0,908 angegeben werden kann.

Die Analyse der Revisionen bzw. ihrer Vorhersagbarkeit besteht aus zwei Teilen. Zum einen werden die In-Sample-Ergebnisse der Vorhersagemodelle *I* bis *VI* in den drei Informationssituationen *A* bis *C* berichtet. Als zweiter Schritt wird überprüft, ob diese Modelle in der Lage sind auch Out-of-Sample die Daten zu verbessern. Für die Out-of-Sample-Analyse wird ein Pseudo-

Echtzeit-Experiment durchgeführt. Das heißt, dass zum Zeitpunkt der Prognose nur die dann bereits veröffentlichten Daten als Informationen für die Schätzung der Modellparameter genutzt werden. Dabei ist zu berücksichtigen, dass zur Schätzung der Modellparameter der Stützzeitraum einen erheblichen Abstand zum Prognosezeitpunkt haben muss. Bei den Kurzzeitrevisionen beträgt dieser acht Quartale, da die Abhängige eben nach zwei Jahren beobachtbar wird. Bei den Langzeitrevisionen existiert die Vergangenheit der vorherzusagende Größe nicht. Wenn die Revision ${}_{t+1+k}y_t - {}_{t+1}y_t$ in $t + 1$ vorhergesagt werden soll, sind in $t + 1$ keinerlei Werte der Zeitreihe $\{{}_{t+1+k}y_t - {}_{t+1}y_t\}_{t=1}^T$ verfügbar, da diese erst in T erstellt wird und k also in der Zeit variiert. Im Pseudo-Echtzeit-Experiment wird dies dadurch angegangen, dass für den Stützzeitraum, die jeweils in $t + 1$ letzten Datenveröffentlichungen als Approximation der “echten” Daten verwendet werden und ein Abstand zwischen Stützzeitraum und Prognosezeitpunkt ($t + 1$) von mindestens drei Jahren eingehalten wird. Die Abhängige für die Regression über den Stützzeitraum ist folglich ${}_{t+1}rev_1, \dots, {}_{t+1}rev_{t-12}$. Mit jedem zusätzlichen Prognosezeitpunkt wird also nicht ein bloß erweiterter, sondern ein erweiterter und revidierter Datensatz für die Regression über den vergrößerten Stützzeitraum verwendet.

In-Sample-Ergebnisse

Die Tabellen 6.1 bis 6.6 geben die Punktschätzungen und deren t -Teststatistiken sowie die Anpassungsgüte der Modelle in Form des R^2 sowie des adjustierten R^2 an. Für die Selektion der Regressoren wurde das adjustierte R^2 als Kriterium verwendet. Bereits die Ergebnisse für das Modell *I* gegeben das Informationsset *A* weisen Evidenz gegen die Hypothese der Datenrationalität auf. Die Konstante ist signifikant positiv, Quartals-Dummies sind signifikant negativ. Der Einfluss einer Saison kann entweder mit Revisionen des Saisonmusters zu tun haben oder mit dem Umstand, dass jährliche oder überjährige Statistiken erstmalig in bestimmten Quartalen vorliegen. Die Hinzunahme von quartalsweise erhobenen bzw. aggregierten Regressoren (bis einschließlich t) im Modell *II* führt zu keiner Verbesserung des adjustierten R^2 im Informationsset *A*. Erst die Berücksichtigung des Folgemonats in den Modellen *III* (Interpolation) und *IV* (MIDAS) bringt einen erheblichen Anstieg der Anpassungsgüte. Anhand der Parameterschätzungen im Modell *IV* für die zusätzlichen Regressoren, zeigt sich, dass diese Konjunkturindikatoren einen positiven Einfluss auf die Revision haben, während der Wert der ersten Veröffentlichung negativ bleibt und signifikant wird. Es erscheint lohnenswert trotz der ersten Veröffentlichungen von BIP-Daten “Now-” bzw. “Backcasting”-Ansätze basierend auf anderen Konjunkturindikatoren zu verfolgen, da diese späteren Datenrevisionen entsprechen können.

In den Modellen *V* und *VI* werden an der Stelle einzelner Regressoren Faktoren aus dem in Appendix A.7 beschriebenen Ansatz eingesetzt. Sie ergeben keine Verbesserung im Vergleich zu den einzelnen Indikatoren Verbrauchervertrauen, Zinsdifferenz und Beschäftigung. Beim Vergleich zwischen dem Interpolationsverfahren und dem MIDAS-Ansatz zeigen sich nur geringe

Tabelle 6.1: Vorhersagemodelle für Langzeitrevisionen des BIP-Wachstums in der USA gegeben A

	I	II	III	IV	V	VI
con	0,574 4,353	0,553 3,444	0,614 4,140	0,576 4,705	0,780 4,619	0,826 5,687
Q2	-0,704 -4,090	-0,710 -3,960	-0,656 -3,494	-0,674 -4,551	-0,656 -3,816	-0,616 -3,473
Q4	-0,485 -2,823	-0,439 -2,361	-0,153 -0,809	-0,246 -1,526	-0,422 -2,448	-0,428 -2,511
$t+1rev_{t-3}$	-0,266 -1,004	-0,228 -0,824	-0,297 -1,055	-0,244 -1,081	-0,324 -1,229	-0,344 -1,372
$t+1y_t$	-0,116 -1,290	-0,202 -1,922	-0,405 -3,728	-0,373 -4,077	-0,281 -2,224	-0,353 -3,181
cs_{t-1}		0,004 0,204	0,023 1,594			
cs_t		0,013 0,694	0,013 0,978			
$cs_{t+1/3}$			0,351 1,959	0,225 3,470		
ysp_{t-1}		0,003 0,015	-0,125 -0,692			
ysp_t		0,198 0,990	1,093 2,528			
$ysp_{t+1/3}$			-0,678 -1,730	0,795 2,377		
$t+1emp_{t-1}$		-0,328 -0,951	0,037 1,970			
$t+1emp_t$		0,622 1,879	0,004 0,012			
$t+1emp_{t+1/3}$			0,377 0,672	1,746 3,597		
$t+1\hat{F}_t$					0,095 1,254	
$t+1\hat{F}_{t+1/3}$					0,135 1,107	0,524 3,256
σ^2	0,344	0,352	0,290	0,219	0,334	0,289
R^2	0,271	0,322	0,477	0,501	0,313	0,342
adR^2	0,227	0,211	0,349	0,389	0,250	0,270

HINWEIS Die Tabelle zeigt die Parameterschätzungen der Vorhersagemodelle in der Informationssituation A .

$t+k y_t - t+1 y_t$ ist die Abhängige. Die t -Statistiken sind untergesetzt.

ABKÜRZUNGEN con: Konstante; Q2: Dummy für das zweite Quartal; Q4: Dummy für das vierte Quartal; cs : Verbrauchervertrauen; ysp : Zinsdifferenz; emp : Beschäftigung; F : geschätzter Faktor.

Tabelle 6.2: Vorhersagemodelle für Langzeitrevisionen des BIP-Wachstums in der USA gegeben B

	III	IV	V	VI
con	0,592 4,419	0,557 5,283	0,798 5,977	0,729 5,401
Q2	-0,617 -3,723	-0,670 -5,011	-0,644 -4,086	-0,668 -4,261
Q4	-0,072 -0,418	-0,252 -1,767	-0,416 -2,641	-0,442 -2,811
$t+1rev_{t-1}$	-0,270 -1,234			
$t+1rev_{t-3}$	-0,370 -1,525	-0,300 -1,399	-0,302 -1,250	-0,256 -1,058
$t+1y_t$	-0,432 -4,435	-0,377 -4,726	-0,290 -3,093	-0,227 -2,453
cs_{t-1}	0,042 3,432			
cs_t	0,021 1,620			
cs_{t+1}	0,020 1,605	0,305 4,891		
$y_{sp_{t-1}}$	-0,070 -0,414			
y_{sp_t}	0,347 2,059			
$y_{sp_{t+1}}$	-0,169 -1,005	0,801 3,701		
$t+1+2/3emp_{t-1}$	0,219 0,649			
$t+1+2/3emp_t$	1,229 2,584			
$t+1+2/3emp_{t+1}$	-0,828 -2,241	2,046 4,494		
$t+1+2/3\hat{F}_{t+1}$			0,202 3,842	0,556 3,971
σ^2	0,242	0,193	0,286	0,255
R^2	0,564	0,560	0,404	0,420
adR^2	0,457	0,462	0,359	0,357

HINWEIS Die Tabelle zeigt die Parameterschätzungen der Vorhersagemodelle in der Informationssituation B . $t+k y_t - t+1 y_t$ ist die Abhängige. Die t -Statistiken sind untergesetzt.

ABKÜRZUNGEN con: Konstante; Q2: Dummy für das zweite Quartal; Q4: Dummy für das vierte Quartal; cs: Verbrauchervertrauen; y_{sp} : Zinsdifferenz; emp : Beschäftigung; F : geschätzter Faktor.

Tabelle 6.3: Vorhersagemodelle für Langzeitrevisionen des BIP-Wachstums in der USA gegeben C

	I	II	III	IV	V	VI
con	0,545 4,261	0,655 4,764	0,575 4,703	0,502 4,526	0,741 5,537	0,670 5,053
Q2	-0,593 -3,570	-0,604 -3,719	-0,523 -3,391	-0,565 -3,929	-0,565 -3,634	-0,598 -4,089
Q4	-0,463 -2,809	-0,410 -2,448	-0,090 -0,564	-0,231 -1,738	-0,412 -2,661	-0,433 -2,819
$t+2rev_t$	-0,169 -0,697	0,177 0,707	0,250 1,104	0,027 0,134	-0,176 -0,778	-0,289 -1,398
$t+2y_t$	-0,149 -1,685	-0,406 -3,603	-0,471 -5,070	-0,413 -4,882	-0,290 -3,109	-0,222 -2,517
cs_t		0,011 0,702	0,026 2,271			
cs_{t+1}		0,000 -0,009	0,020 1,734			
cs_{t+2}		0,012 0,764	0,022 1,877	0,253 4,282		
y_{sp_t}		0,005 1,046	-0,027 -0,177			
$y_{sp_{t+1}}$		-0,004 -0,844	0,416 2,650			
$y_{sp_{t+2}}$		0,001 0,426	-0,186 -1,167	0,947 2,831		
$t+2emp_t$		-0,753 -2,619	0,018 0,059			
$t+2emp_{t+1}$		0,535 1,525	1,544 3,493			
$t+2emp_{t+2}$		0,706 2,424	-0,957 -2,807	2,182 4,754		
$t+2\hat{F}_t$						
$t+2\hat{F}_{t+1}$					0,170 3,254	0,460 3,343
σ^2	0,308	0,268	0,203	0,170	0,269	0,243
R^2	0,252	0,438	0,575	0,556	0,357	0,366
adR^2	0,207	0,310	0,478	0,454	0,307	0,295

HINWEIS Die Tabelle zeigt die Parameterschätzungen der Vorhersagemodelle in der Informationssituation C . $t+k y_t - t+2 y_t$ ist die Abhängige. Die t -Statistiken sind untergesetzt.

ABKÜRZUNGEN con: Konstante; Q2: Dummy für das zweite Quartal; Q4: Dummy für das vierte Quartal; cs : Verbrauchervertrauen; y_{sp} : Zinsdifferenz; emp : Beschäftigung; F : geschätzter Faktor.

Tabelle 6.4: Vorhersagemodelle für Kurzzeitrevisionen des BIP-Wachstums in der USA gegeben A

	I	II	III	IV	V	VI
con	0,237 2,567	0,2709 2,959	0,265 2,967	0,251 3,257	0,265 2,857	0,243 2,301
Q2	-0,407 -2,545	-0,4262 -2,714	-0,505 -3,047	-0,454 -3,463	-0,413 -2,606	-0,377 -2,562
Q4	-0,411 -2,568	-0,4716 -2,888	-0,287 -1,707	-0,295 -2,221	-0,383 -2,405	-0,413 -2,398
$t+1rev_{t-1}$			-0,309 -1,412	-0,404 -2,052		-0,175 -0,795
cs_{t-1}		0,013 0,823	0,037 2,645			
cs_t		0,027 1,728	0,011 0,878			
$cs_{t+1/3}$			0,004 0,022	0,223 4,073		
ysp_{t-1}		0,355 2,162	0,303 1,849			
ysp_t		-0,106 -0,654	-0,134 -1,288			
$ysp_{t+1/3}$			0,159 1,726	1,302 2,844		
$t+1cu_{t-1}$			0,042 2,373			
$t+1cu_t$			0,219 0,718			
$t+1cu_{t+1/3}$			0,245 1,855	0,464 1,804		
$t+1\hat{F}_t$					-0,014 -0,247	
$t+1\hat{F}_{t+1/3}$					0,193 1,702	0,155 1,433
σ^2	0,307	0,286	0,258	0,195	0,308	0,285
R^2	0,124	0,232	0,370	0,420	0,185	0,151
adR^2	0,099	0,161	0,242	0,302	0,110	0,072

HINWEIS Die Tabelle zeigt die Parameterschätzungen der Vorhersagemodelle in der Informationssituation A . $t+8y_t - t+1y_t$ ist die Abhängige. Die t -Statistiken sind untergesetzt.

ABKÜRZUNGEN con: Konstante; Q2: Dummy für das zweite Quartal; Q4: Dummy für das vierte Quartal; cs : Verbrauchervertrauen; ysp : Zinsdifferenz; cu : Kapazitätsauslastung; F : geschätzter Faktor.

Unterschiede, die zwischen den Informationssets variieren. Generell führt die Berücksichtigung von mehr Informationen am aktuellen Rand zu eindeutigen Verbesserungen der Modellanpassung. Dies zeigen der Übergang von Modell II zu den Modellen III und IV im Informationsset A sowie der Übergang von A nach B . Die adjustierten R^2 der Modelle III und IV steigen von 0,349 und 0,389 auf 0,457 und 0,462. Die wesentlichen Tendenzen der Parameterschätzungen werden durch das Informationsset B verglichen mit A nicht verändert.

Mit der Berücksichtigung der ersten Revision auf der linken wie der rechten Seite der Vorhersagemodelle soll überprüft werden, ob die in den Vorhersagemodellen verarbeitete Information bereits in der ersten Revision von der datenberichtenden Agentur aufgenommen wird und die Vorhersagemodelle nach einem weiteren Quartal obsolet werden. Tabelle 6.3 gibt die entspre-

Tabelle 6.5: Vorhersagemodelle für Kurzzeitrevisionen des BIP-Wachstums in der USA gegeben B

	III	IV	V	VI
con	0,286 3,514	0,240 3,199	0,277 3,370	0,268 3,931
Q2	-0,426 -2,805	-0,368 -2,793	-0,368 -2,560	-0,353 -2,703
Q4	-0,382 -2,521	-0,384 -3,073	-0,364 -2,559	-0,357 -2,943
$t+1rev_{t-1}$	-0,375 -1,837	-0,383 -1,965	-0,289 -1,421	-0,406 -2,125
cs_{t-1}	0,023 1,860			
cs_t	0,018 1,226			
cs_{t+1}	0,008 0,673	0,017 0,955		
ysp_{t-1}	0,087 0,532			
ysp_t	-0,151 -0,872			
ysp_{t+1}	0,311 2,134	-0,198 -0,840		
$t+1+2/3cu_{t-1}$	0,252 2,935			
$t+1+2/3cu_t$	-0,124 -1,299			
$t+1+2/3cu_{t+1}$	0,101 1,187	-0,884 -5,775		
$t+1+2/3\hat{F}_t$			0,262 4,623	
$t+1+2/3\hat{F}_{t+1}$			-0,125 -2,189	0,619 6,359
σ^2	0,211	0,159	0,239	0,201
R^2	0,484	0,493	0,347	0,401
adR^2	0,380	0,390	0,297	0,346

HINWEIS Die Tabelle zeigt die Parameterschätzungen der Vorhersagemodelle in der Informationssituation B . $t+8y_t - t+1y_t$ ist die Abhängige. Die t -Statistiken sind untergesetzt.

ABKÜRZUNGEN con: Konstante; Q2: Dummy für das zweite Quartal; Q4: Dummy für das vierte Quartal; cs : Verbrauchervertrauen; ysp : Zinsdifferenz; cu : Kapazitätsauslastung; F : geschätzter Faktor.

Tabelle 6.6: Vorhersagemodelle für Kurzzeitrevisionen des BIP-Wachstums in der USA gegeben C

	I	II	III	IV	V	VI
con	0,150 1,877	0,185 2,324	0,335 2,865	0,285 8,317	0,287 2,349	0,292 2,871
Q2	-0,264 -1,910	-0,293 -2,145	-0,225 -1,647	-0,236 -2,288	-0,247 -1,913	-0,242 -1,976
Q4	-0,373 -2,692	-0,434 -3,062	-0,430 -3,134	-0,394 -9,426	-0,309 -2,362	-0,328 -2,665
$t+1rev_{t-1}$		0,023 1,698	-0,128 -1,572	-0,107 -2,654	-0,092 -1,106	-0,108 -1,686
cs_{t-1}		0,013 0,977	0,006 0,502			
cs_t		0,281 1,971	0,003 0,213			
cs_{t+1}		-0,019 -0,134	0,013 1,173	0,060 1,562		
$y_{sp_{t-1}}$			0,071 0,485			
y_{sp_t}			-0,281 -1,813			
$y_{sp_{t+1}}$			0,259 1,870	0,608 2,448		
$t+1+2/3cu_{t-1}$			0,243 3,134			
$t+1+2/3cu_t$			-0,007 -0,071			
$t+1+2/3cu_{t+1}$			-0,072 -0,936	0,575 5,919		
$t+1+2/3\hat{F}_{t-1}$					0,181 3,525	
$t+1+2/3\hat{F}_t$					-0,032 -0,531	
$t+1+2/3\hat{F}_{t+1}$					-0,046 -1,387	0,442 4,080
σ^2	0,230	0,216	0,173	0,139	0,198	0,176
R^2	0,109	0,211	0,428	0,438	0,279	0,289
adR^2	0,083	0,138	0,312	0,323	0,212	0,224

HINWEIS Die Tabelle zeigt die Parameterschätzungen der Vorhersagemodelle in der Informationssituation C .

$t+8y_t - t+2y_t$ ist die Abhängige. Die t -Statistiken sind untergesetzt.

ABKÜRZUNGEN con: Konstante; Q2: Dummy für das zweite Quartal; Q4: Dummy für das vierte Quartal; cs : Verbrauchervertrauen; y_{sp} : Zinsdifferenz; cu : Kapazitätsauslastung; F : geschätzter Faktor.

chenden Ergebnisse wieder. Die Vorhersagemodelle behalten auch nach der ersten Revision ihren Wert; die Richtungen der Parameterschätzungen sind analog zu denen ohne Berücksichtigung der ersten Revisionen. Insbesondere fällt auf, dass Modell *II* im Informationsset *C* bedeutend besser abschneidet als im Informationsset *A*, wobei in *C* auch zusätzliche Informationen in das Modell *II* verglichen mit dem Informationsset *A* einfließen. Auch nach der ersten Revision sind die Vorhersagemodelle von Relevanz. Die erste Revision enthält nicht alle Informationen, die von den Vorhersagemodellen berücksichtigt werden.

Die Vorhersagemodelle werden nicht nur für Langzeitrevisionen, sondern auch für Kurzzeitrevisionen mit einem festen Horizont von acht Quartalen eingesetzt. Die Tabellen 6.4 bis 6.6 geben die entsprechenden Ergebnisse wieder. Verglichen mit den Ergebnissen für die Langzeitrevisionen weisen die Vorhersagemodelle deutlich schlechterer Anpassungsgüten auf. Es fällt auf, dass der Wert der ersten Veröffentlichung $t+1y_t$ keine Rolle mehr spielt. Dass die Kurzzeitrevisionen schlechter zu erklären sind als die Langzeitrevisionen, bestätigt das Ergebnis von Faust et al. (2005), die allerdings noch schlechtere Anpassungsgüten finden. Es zeigt sich an dieser Stelle insbesondere der Vorteil Informationen am aktuellen Rand zu berücksichtigen. So steigen die adjustierten R^2 -Werte der Modelle *III* bis *VI* erheblich zwischen Informationsset *A* und *B* an. Ferner zeigt sich, dass bezogen auf die Kurzzeitrevisionen die Variable Beschäftigung einen geringeren Einfluss hat.¹⁵ Dafür tritt die Kapazitätsauslastung zum Teil an ihre Stelle. Gegeben die Informationssituation *B* ist sie in Modell *IV* der einzige signifikante Regressor unter den Konjunkturvariablen. Bezogen auf die Kurzzeitrevisionen ist der Einfluss der ersten Revision stärker als auf die Langzeitrevisionen, so dass die Erklärungsgüte der Vorhersagemodelle im Informationsset *C* deutlich schlechter ist als gegeben *B*. Die erste Revision scheint einige der Informationen, die gegeben *B* in den Vorhersagemodellen bezogen auf die Kurzzeitrevisionen stecken, aufzunehmen.

Out-of-Sample-Ergebnisse

In der Out-of-Sample-Analyse der Prognosegüte soll überprüft werden, ob die bereits diskutierten Vorhersagemodelle von tatsächlicher Bedeutung am aktuellen Rand sind bzw. ob sie es in einem bestimmten Zeitraum der Stichprobe gewesen wären. Die Out-of-Sample-Analyse besteht aus schrittweisen Prognosen von Werten der Stichprobe, wobei die Prognosen mit den tatsächlichen Realisationen verglichen werden. Die gesamte Stichprobe umfasst 72 Beobachtungen. Die letzten 20 Beobachtungen werden als Prognosezeitraum gewählt und die Prognosen schrittweise von der ersten zur zwanzigsten durchgeführt. Der korrespondierende Stützzeitraum, auf dem die Parameter der Prognosemodelle geschätzt werden, wird mit jedem Prognoseschritt wie erläutert

¹⁵Im Informationsset *C* ist der Unterschied zwischen Kapazitätsauslastung und Beschäftigung gering. In der Out-of-Sample-Analyse wird gegeben Set *C* Beschäftigung als Regressor an Stelle der Kapazitätsauslastung berücksichtigt, da dies zu besseren Ergebnissen führt. Gemeinsam verbessern beide Variablen die Ergebnisse nicht.

Tabelle 6.7: MSFE – Langzeitrevisionen – USA

	rel. zu kein Modell	rel. zu Modell <i>I</i>
kein Modell	1,000	1,113
<i>I</i> _A	0,899	1,000
<i>II</i> _A	1,051	1,169
<i>III</i> _A	0,780	0,868
<i>IV</i> _A	0,722	0,803
<i>V</i> _A	0,884	0,984
<i>VI</i> _A	2,881	3,206
<i>III</i> _B	0,633	0,705
<i>IV</i> _B	0,691	0,769
<i>V</i> _B	0,798	0,888
<i>VI</i> _B	0,971	1,080

Hinweis: Basierend auf 20 Vorhersagen (${}_{t+k}y_t - {}_{t+1}y_t$). Kein Modell bedeutet, dass Datenrationalität angenommen wird.

erweitert. Es soll jeweils die Information zur Prognose verwendet werden, die auch in Echtzeit zur Verfügung stand. Um Vorhersagemodelle für Langzeitrevisionen zu schätzen, müssen hinreichend lange Revisionszeiten gewahrt bleiben (drei Jahre werden angenommen). Der Stützzeitraum wird dadurch zusätzlich verringert, so dass die erste Prognose (53. Beobachtung) nicht auf einem Stützzeitraum mit 52 Beobachtungen fußt, sondern nur mit 40.

Tabelle 6.7 zeigt die mittleren quadratischen Vorhersagefehler der Vorhersagemodelle im Verhältnis zu den mittleren quadratischen Revisionen selbst (kein Modell) und zu den mittleren quadratischen Vorhersagefehlern des Modells *I*, das im Hinblick auf die Hinzunahme zusätzlicher Konjunkturindikatoren als Regressoren als Benchmark dient. Analog zu den In-Sample-Ergebnissen schneiden die Modelle *III* und *IV* am besten ab, insbesondere wenn das Informationsset *B* berücksichtigt wird. Ebenfalls analog zu den In-Sample-Ergebnissen schneidet Modell *II* sehr schlecht ab und weist hier sogar größere Prognosefehler auf als die Annahme der Datenrationalität (kein Modell). Im Hinblick auf das Modell *VI* ist zu erwähnen, dass die Gewichtungparameter des MIDAS-Modells im Zusammenspiel mit dem einzelnen Faktor sehr instabil im Zeitverlauf sind und daher Modell *VI* sehr schlechte Prognosen liefert.

Wegen der geringen Anzahl von Prognosen ist eine weitergehende Prognoseevaluation nur eingeschränkt sinnvoll. Tabelle 6.8 zeigt die Werte der Diebold-Mariano-Teststatistik, siehe Abschnitt 2.6.2 für eine Darstellung der Teststatistik. Für den Vergleich nicht genisteter Modelle kann eine *t*-Verteilung mit 19 Freiheitsgraden unterstellt werden.¹⁶ Die Variante ohne Modell und das Modell *I* lassen sich aus den anderen Modellen durch Parameterrestriktionen herleiten, so dass asymptotisch unter der Nullhypothese des restringierten Modells beide identische Prognosen liefern würden. Somit ist die asymptotische Verteilung nicht die Normalverteilung.

¹⁶Vgl. Harvey et al. (1997).

Tabelle 6.8: Diebold-Mariano-Test – Langzeitrevisionen – USA

	<i>I</i>	<i>II</i>	<i>III</i>	<i>IV</i>	<i>V</i>	<i>VI</i>	<i>III_B</i>	<i>IV_B</i>	<i>V_B</i>	<i>VI_B</i>
kein M.	0,978 [†]	-0,260	1,149 [‡]	1,195 [‡]	0,687 [†]	-0,964	1,874 [‡]	1,845 [‡]	0,972 [†]	0,088
<i>I</i>	–	-1,253	0,778 [†]	0,908 [†]	0,129	-0,986	1,453 [‡]	1,550 [‡]	0,562	-0,236
<i>II</i>	–	–	1,973*	1,751*	1,195	-0,955	2,028*	1,226	1,183	0,338
<i>III</i>	–	–	–	0,801	-1,084	-1,012	0,992	-0,036	-0,151	-0,727
<i>IV</i>	–	–	–	–	-1,059	-1,054	-0,391	-1,239	-0,795	-1,065
<i>V</i>	–	–	–	–	–	-0,990	1,252	0,473	0,697	-0,260
<i>VI</i>	–	–	–	–	–	–	1,042	1,009	1,007	1,020
<i>III_B</i>	–	–	–	–	–	–	–	-1,235	-0,966	-1,187
<i>IV_B</i>	–	–	–	–	–	–	–	–	-0,064	-0,567
<i>V_B</i>	–	–	–	–	–	–	–	–	–	-0,687

Hinweis: Basierend auf 20 Vorhersagen (${}_{t+k}y_t - {}_{t+1}y_t$). Bei nicht-genisteten Modellen liegt ein zweiseitiger Test vor. Die kritischen Werte werden einer t -Verteilung mit 19 Freiheitsgraden entnommen. Interpretation: Signifikant positive Werte korrespondieren zu besseren Vorhersagemodellen in den Spalten; signifikant negative Werte korrespondieren zu besseren Vorhersagemodellen in den Zeilen. *: Signifikant zum 10 % Niveau.

Bei genisteten Modellen ist der Test einseitig und es werden die asymptotischen kritischen Werte aus McCracken (1999) entnommen. †: Signifikant zum 5% Niveau. ‡: Signifikant zum 1% Niveau.

Die tatsächlichen kritischen Werte sind kleiner und nur ein rechtsseitiger Test erscheint sinnvoll. An dieser Stelle werden die asymptotischen kritischen Werte von McCracken (1999) angewendet, da nur Ein-Schritt-Prognosen evaluiert werden und mit Einschränkung der nicht-linearen Gewichtung im MIDAS lineare Modelle verglichen werden.¹⁷ Der Encompassing-Test von Harvey et al. (1998) oder dessen Reinterpretation für genistete Modelle entsprechend Clark und West (2007) werden in diesem Kontext nicht verwendet, da die Prognosen einiger Modelle im Mittel signifikant von null abweichen und dies eine grundlegende Forderung für die Gültigkeit der asymptotischen Verteilungen, wie sie von Harvey et al. (1998) bzw. Clark und West (2007) verwendet werden, ist.

Unter dem Vorbehalt, dass die Modelle genistet sind, bringen die Varianten *III_B* und *IV_B* Evidenz besser zu prognostizieren als die Variante ohne Modell und das Modell *I*. Die Prognosen des Modells *II* sind zum 10 % Niveau schlechter als die der Modelle *III* und *IV* für beide Informationssets *A* und *B*. Im Informationsset *B* ist Modell *III* auch zum 5 % Niveau besser. Der Vergleich der Modelle mit monatlichen Regressoren untereinander zeigt keine signifikanten Ergebnisse.

Auch für die Out-of-Sample-Analyse soll überprüft werden, welche Position die Vorhersagemodelle einnehmen, wenn die erste Datenrevision der datenberichtenden Agentur veröffentlicht worden ist. Tabelle 6.9 zeigt die mittleren quadratischen Abweichungen der Vorhersagemodelle

¹⁷Wegen der geringen Anzahl an Beobachtungen sind die asymptotischen Testergebnisse entsprechend vorsichtig zu interpretieren.

Tabelle 6.9: MSFE – Langzeitrevisionen nach der ersten Revision (C) – USA

	rel. zu kein Modell	rel. zu Modell I
kein Modell	1,000	0,957
I	1,045	1,000
II	1,265	1,210
III	0,614	0,588
IV	0,742	0,709
V	0,925	0,885
VI	2,156	2,063

Hinweis: Basierend auf 19 Vorhersagen (${}_{t+k}y_t - {}_{t+2}y_t$). Kein Modell bedeutet, dass Datenrationalität angenommen wird.

Tabelle 6.10: Diebold-Mariano-Test – Langzeitrevisionen nach der ersten Revision (C) – USA

	I	II	III	IV	V	VI
no m.	-0,324	-0,895	1,866 [‡]	1,089 [‡]	0,342	-0,788
I	–	-0,862	1,768 [‡]	1,267 [‡]	0,481	-0,744
II	–	–	2,523 ^{**}	1,573	1,068	-0,587
III	–	–	–	-0,662	-1,666	-1,055
IV	–	–	–	–	-0,729	-0,964
V	–	–	–	–	–	-0,835

Hinweis: Basierend auf 19 Vorhersagen (${}_{t+k}y_t - {}_{t+1}y_t$). Bei nicht-genisteten Modellen liegt ein zweiseitiger Test vor. Die kritischen Werte werden einer t -Verteilung mit 18 Freiheitsgraden entnommen. Interpretation: Signifikant positive Werte korrespondieren zu besseren Vorhersagemodellen in den Spalten; signifikant negative Werte korrespondieren zu besseren Vorhersagemodellen in den Zeilen. *: Signifikant zum 10 % Niveau. **: Signifikant zum 5 % Niveau.

Bei genisteten Modellen ist der Test einseitig und es werden die asymptotischen kritischen Werte aus McCracken (1999) entnommen. †: Signifikant zum 10% Niveau. ‡: Signifikant zum 5% Niveau.

Tabelle 6.11: MSFE – Kurzzeitrevisionen – USA

	rel. zu kein Modell	rel. zu Modell <i>I</i>
kein Modell	1,000	1,101
<i>I_A</i>	0,909	1,000
<i>II_A</i>	0,968	1,066
<i>III_A</i>	0,945	1,041
<i>IV_A</i>	0,860	0,947
<i>V_A</i>	1,069	1,177
<i>VI_A</i>	1,028	1,131
<i>III_B</i>	0,656	0,722
<i>IV_B</i>	0,777	0,856
<i>V_B</i>	0,776	0,854
<i>VI_B</i>	1,019	1,121

Hinweis: Basierend auf 20 Vorhersagen (${}_{t+8}y_t - {}_{t+1}y_t$). Kein Modell bedeutet, dass Datenrationalität angenommen wird.

und Tabelle 6.10 die korrespondierenden Werte der Diebold-Mariano-Teststatistik. Da nun die erste Revision “abgewartet” wird, reduziert sich der Prognoseumfang um eine Beobachtung. Insbesondere Modell *III* schneidet auch unter Informationsset *C* gut ab. Relativ zur Variante, in der kein Modell angenommen wird, hat Modell *III* einen MSFE von 0,614. Ferner weist es eine *DM*-Teststatistik von 1,866 auf und relativ zu Modell *I* 1,768. Selbst unter der zu konservativen Annahme einer *t*-Verteilung mit 18 Freiheitsgraden entspräche dies einem Signifikanzniveau von 10 % (zweiseitig). Der MIDAS-Ansatz (Modell *IV*) weist im Fall einzelner Regressoren an dieser Stelle etwas schlechtere Ergebnisse auf als die Interpolation (Modell *III*). Im Fall des einzelnen Faktors als Regressor führt die Parameterinstabilität im Modell *VI* wiederum zu sehr schlechten Ergebnissen.

Neben den Langzeitrevisionen, die sich fortwährend am aktuellen Rand für die gesamte Stichprobe ändern, werden Kurzzeitrevisionen mit einem festen Horizont von zwei Jahren betrachtet. Der feste Zeithorizont vereinfacht die Out-of-Sample-Analyse, da sich nun die Abhängige im Fortgang der Prognose nicht mehr ändert. Ferner kann der Abstand zwischen Prognose- und Stützzeitraum auf die besagten zwei Jahre reduziert werden.

Tabelle 6.11 zeigt die mittleren quadratischen Abweichungen der Vorhersagemodelle. Gegeben das Informationsset *A* zeigen die Vorhersagemodelle kaum Verbesserungen im Vergleich zur Variante ohne Modell. Von den Modellen mit monatlichen Regressoren ist nur *IV* besser als das Modell *I*. Wird das Informationsset erweitert zeigt sich der Vorteil der Berücksichtigung von Daten am aktuellen Rand auch Out-of-Sample. Die Modelle *III*, *IV* und *V* weisen unter Informationsset *B* deutlich geringere MSFE auf als die anderen Modelle.

Tabelle 6.12 gibt die Werte der Diebold-Mariano-Teststatistik an. Zwischen den nicht-genisteten Modellen, die die Annahme einer *t*-Verteilung rechtfertigen, gibt es nur eine Beziehung

Tabelle 6.12: Diebold-Mariano-Test – Kurzzeitrevisionen – USA

	<i>I</i>	<i>II</i>	<i>III</i>	<i>IV</i>	<i>V</i>	<i>VI</i>	<i>III_B</i>	<i>IV_B</i>	<i>V_B</i>	<i>VI_B</i>
kein M.	0,757 [†]	0,178	0,186	0,481	-0,263	-0,107	1,502 [‡]	0,971 [‡]	0,662 [†]	-0,042
<i>I</i>	–	-0,803	-0,172	0,236	-0,781	-0,595	1,294 [‡]	0,663	0,410	-0,259
<i>II</i>	–	–	0,127	0,581	-0,467	-0,285	1,563	0,978	0,566	-0,117
<i>III</i>	–	–	–	0,876	-0,493	-0,340	1,326	0,834	0,456	-0,163
<i>IV</i>	–	–	–	–	-0,867	-0,712	1,081	0,459	0,263	-0,365
<i>V</i>	–	–	–	–	–	2,233**	1,608	1,136	1,189	0,169
<i>VI</i>	–	–	–	–	–	–	1,505	1,018	1,048	0,029
<i>III_B</i>	–	–	–	–	–	–	–	-1,863*	-0,498	-0,985
<i>IV_B</i>	–	–	–	–	–	–	–	–	0,006	-0,620
<i>V_B</i>	–	–	–	–	–	–	–	–	–	-1,699

Hinweis: Basierend auf 20 Vorhersagen (${}_{t+8}y_t - {}_{t+2}y_t$). Bei nicht-genisteten Modellen liegt ein zweiseitiger Test vor. Die kritischen Werte werden einer t -Verteilung mit 19 Freiheitsgraden entnommen. Interpretation: Signifikant positive Werte korrespondieren zu besseren Vorhersagemodellen in den Spalten; signifikant negative Werte korrespondieren zu besseren Vorhersagemodellen in den Zeilen. *: Signifikant zum 10 % Niveau. **: Signifikant zum 5 % Niveau.

Bei genisteten Modellen ist der Test einseitig und es werden die asymptotischen kritischen Werte aus McCracken (1999) entnommen. †: Signifikant zum 10% Niveau. ‡: Signifikant zum 5% Niveau.

die ein signifikanten Wert zu einem Standardniveau aufweist: Modell *VI* ist signifikant besser als Modell *V*. Das beste Modell entsprechend des MSFE, *III_B*, weist keine signifikanten Dominanzverhältnisse zu nicht-genisteten Modellen auf. Der Wert 1,502 im Vergleich mit der genisteten Variante ohne Modell kann aber als Evidenz für eine Verbesserung der Prognosen gewertet werden insbesondere, wenn man den Wert mit dem kritischen Wert von McCracken (1999) vergleicht. Insgesamt ist der Stichprobenumfang der Prognosen sehr gering, insbesondere im Verhältnis zu der Zahl der geschätzten Parameter, was sich entsprechend auch auf die Qualität der Diagnostik auswirkt.

Tabelle 6.13: MSFE – Kurzzeitrevisionen nach der ersten Revision (*C*) – USA

	rel. zu kein Modell	rel. zu Modell <i>I</i>
kein Modell	1,000	0,894
<i>I</i>	1,119	1,000
<i>II</i>	1,312	1,173
<i>III</i>	0,847	0,757
<i>IV</i>	1,184	1,058
<i>V</i>	1,195	1,068
<i>VI</i>	1,298	1,161

Hinweis: Basierend auf 19 Vorhersagen (${}_{t+8}y_t - {}_{t+1}y_t$). Kein Modell bedeutet, dass Datenrationalität angenommen wird.

Tabelle 6.14: Diebold-Mariano-Test – Kurzzeitrevisionen nach der ersten Revision (C) – USA

	I	II	III	IV	V	VI
kein Modell	-0,818	-1,532	0,644 [†]	-0,648	-0,381	-0,862
I	–	-1,682	1,073 [‡]	-0,282	-0,156	-0,627
II	–	–	1,524	0,476	0,215	0,037
III	–	–	–	-1,781*	-0,699	-1,194
IV	–	–	–	–	-0,024	-0,339
V	–	–	–	–	–	-0,326

Hinweis: Basierend auf 19 Vorhersagen (${}_{t+s}y_t - {}_{t+1}y_t$). Bei nicht-genisteten Modellen liegt ein zweiseitiger Test vor. Die kritischen Werte werden einer t -Verteilung mit 18 Freiheitsgraden entnommen. Interpretation: Signifikant positive Werte korrespondieren zu besseren Vorhersagemodellen in den Spalten; signifikant negative Werte korrespondieren zu besseren Vorhersagemodellen in den Zeilen. *: Signifikant zum 10 % Niveau.

Bei genisteten Modellen ist der Test einseitig und es werden die asymptotischen kritischen Werte aus McCracken (1999) entnommen. †: Signifikant zum 10% Niveau. ‡: Signifikant zum 5% Niveau.

Auch im Fall der Kurzzeitrevisionen wird das Informationsset C berücksichtigt, also die Auswirkung der ersten Revision analysiert. Nur Modell III zeigt einen niedrigeren MSFE als die Variante ohne Modell, siehe Tabelle 6.13. Die einzige signifikante Beziehung, die zwischen zwei nicht-genisteten Modellen gefunden werden konnte, ist, dass Modell III zum 5% Niveau besser vorhersagt als Modell IV , siehe Tabelle 6.14. Gegeben die kritischen Werte von McCracken (1999) ist Modell III signifikant besser als die Alternative ohne Modell sowie das Modell I zum 10 % bzw. 5 % Niveau.

Viele der Informationen, die durch die Vorhersagemodelle im Bezug auf die Kurzzeitrevisionen inkorporiert werden, scheinen bereits in der ersten Revision Berücksichtigung zu finden. Dazu sei erwähnt, dass an dieser Stelle nicht die Kapazitätsauslastung als Regressor im Modell III auftritt, wie in den Informationssets A und B , sondern die Beschäftigung, wie in der Analyse der Langzeitrevisionen. Kurzzeitrevisionen, sofern die erste Revision berücksichtigt wird, können eindeutig schlechter vorhergesagt werden als Langzeitrevisionen.

Die Analyse der Datenrevisionen des BIP-Wachstums der USA zeigen, dass Vorhersagen insbesondere der Langzeitrevisionen möglich sind. Dabei ist die Berücksichtigung von Informationen am aktuellen Rand durch gemischt-frequente Modelle zu empfehlen. Der MIDAS-Ansatz hat sich dabei In-Sample als vielversprechend erwiesen, zeigt jedoch wegen Parameterinstabilitäten keine Vorteile in der Out-of-Sample-Analyse gegenüber der Interpolation. In der bisherigen Arbeit zeigten sich Modelle, die mit einzelnen Regressoren arbeiten, Ansätzen mit Faktormodellen überlegen. Hier kann vermutet werden, dass mit der Zugänglichkeit größerer Echtzeitdatensätze Faktormodelle an Bedeutung gewinnen.

Es zeigt sich, dass Kurzzeitrevisionen schlechter erklärt und vorhergesagt werden können. Die

erste Revision nimmt anscheinend viele der Informationen auf, die auch in den Vorhersagemodellen eine Rolle spielen. Anzumerken ist hier die zum Teil erhebliche Variation der Koeffizienten der einzelnen Regressoren zwischen den Informationssets. Die schlechte Prognostizierbarkeit von Kurzzeitrevisionen im Vergleich zu Langzeitrevisionen ist im Einklang mit den Ergebnissen von Faust et al. (2005).

6.3.3 Datenrevisionen des deutschen BSP

Abbildung 6.2 zeigt in der oberen Hälfte das Wachstum des realen und saisonbereinigten BSP für Deutschland entsprechend der ersten Veröffentlichungen und in der unteren Hälfte die dazugehörigen Revisionen nach zwei Jahren. Berücksichtigt werden Daten zwischen 1973 und 1993 (insgesamt 80 Beobachtungen). Langzeitrevisionen werden für die deutschen Daten nicht betrachtet.¹⁸ Die Standardabweichung des BSP-Wachstums der ersten Veröffentlichungen beträgt 1,303. Nach Berücksichtigung der zweijährigen Revisionen beträgt die Standardabweichung 1,025. Bereits dieses Ergebnis spricht gegen Datenrationalität und unterstützt die Ergebnisse von Faust et al. (2005), die für deutsche Daten bezüglich des realen Output klare Evidenz gegen Datenrationalität finden.¹⁹

In-Sample-Ergebnisse

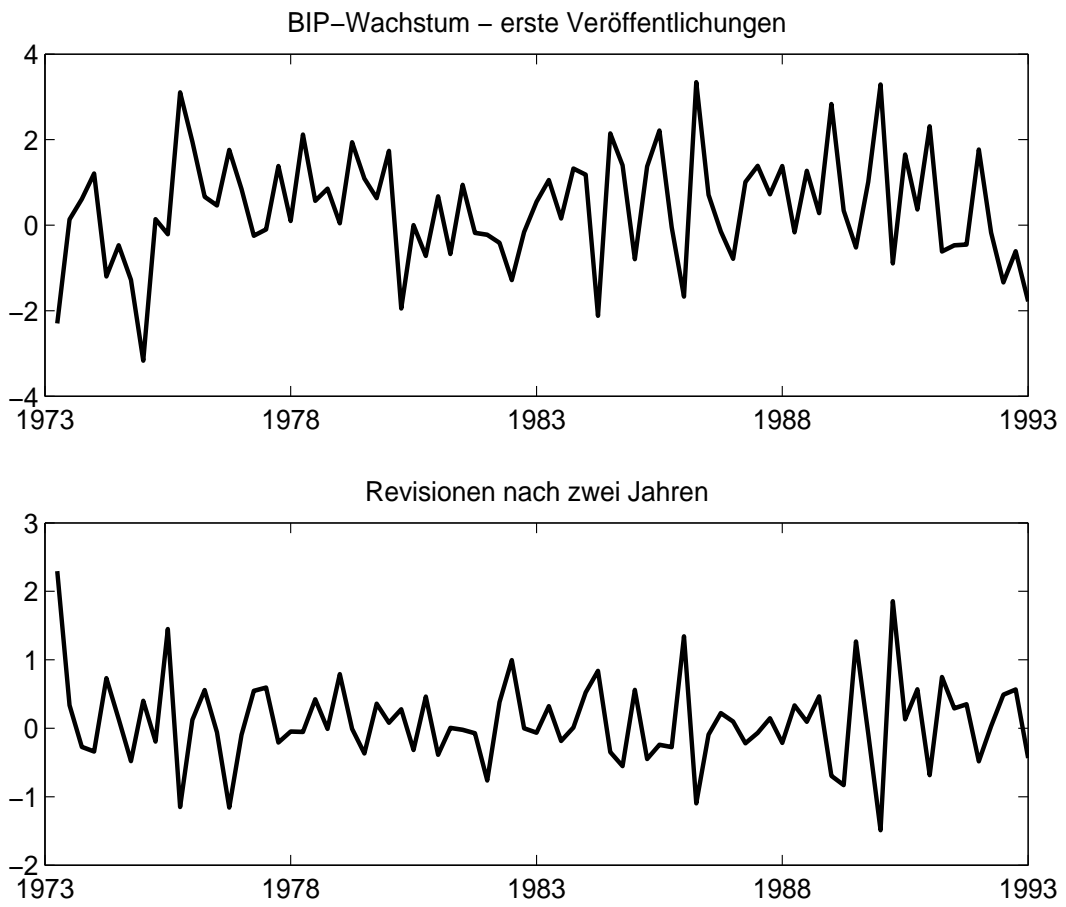
Für das deutsche BSP-Wachstum werden nur Ergebnisse zu Kurzzeitrevisionen besprochen.²⁰ Die Ergebnisse der Vorhersagemodelle, die sowohl für das Informationsset *A* als auch *B* in Tabelle 6.15 dargestellt sind, entsprechen der Vermutung, dass die Hypothese der Datenrationalität für deutsche Daten zu verwerfen ist. Bereits das Modell *I* weist ein adjustiertes R^2 von 0,516 auf. Neben saisonalen Einflüssen, die Faust et al. (2005) in ihrem Datensatz nicht finden, ist insbesondere die erste Veröffentlichung ein hoch signifikanter Regressor mit negativem Koeffizienten. Die Erweiterung des Modells mit Konjunkturindikatoren, namentlich dem Konjunkturklima-Index des Ifo-Instituts, der Arbeitslosenzahlen sowie der Quartalsrenditen des C-DAX, in den

¹⁸Langzeitrevisionen bezögen sich auf die Differenz der Daten gemäß der ersten Veröffentlichung zu den letzten Veröffentlichungen. Mitte der 90er Jahre hat eine erhebliche Anpassung der Volkswirtschaftlichen Gesamtrechnung hinzu internationalen Standards stattgefunden, siehe z.B. Statistisches Bundesamt (2002). Dieser Effekt würde bei der Analyse der Langzeitrevisionen eine erhebliche Rolle spielen, ist aber nicht Gegenstand oder Ziel der Untersuchung.

¹⁹Faust et al. (2005) verwenden BIP-Daten des Zeitraums 1979 bis 1994, die sie den einzelnen Veröffentlichungen der OECD entnommen haben.

²⁰Da es sich um einen mehr oder minder historischen Datensatz handelt, der in 1994 abbricht, ist es unklar ob nun die dort zuletzt geführte Veröffentlichung oder die jüngste Veröffentlichung zur Berechnung der Langzeitrevisionen verwendet werden sollte. Insbesondere im Hinblick auf die methodischen Veränderungen in der Volkswirtschaftlichen Gesamtrechnung Mitte der 90er Jahre erscheint die Langzeitperspektive für diesen Datensatz nicht angebracht.

Abbildung 6.2: Datenrevisionen – Deutschland



Modellen *II* bis *IV* führt zu weiteren Verbesserungen der Modellanpassung.²¹

Im Vergleich mit den Ergebnissen für die US-Daten fallen erhebliche Unterschiede auf. Die Aufnahme von zusätzlichen Konjunkturindikatoren verbessert die Anpassungsgüte der Modelle, so steigt das adjustierte R^2 in Modell *II* auf 0,634. Die zusätzliche Berücksichtigung von Informationen am aktuellen Rand durch die Modelle *III* und *IV* oder durch die gleichen Modelle gegeben das Informationsset *B* führt nur zu sehr geringen Verbesserungen, im Fall des MIDAS-Modell sogar zu einem leichten Rückgang des adjustierten R^2 im Vergleich zum Modell *II*. Das Konjunkturklima und der C-DAX gelten als Frühindikatoren, so dass sie ihre Informationen für die Konjunktur zum Zeitpunkt t bereits in t bzw. sogar früher enthalten. In diesem Zusammenhang ist das Ergebnis für die Arbeitslosenzahlen problematisch. Zwar ist der negative Koeffizient ein Hinweis, dass diese auch zur Abbildung der tatsächlichen Konjunktursituation beizutragen scheinen, da die Arbeitslosenzahlen allgemein eher als nachlaufender Indikator gelten, ist der starke Einfluss der verzögerten Arbeitslosenzahlen allerdings bemerkenswert.

Ebenfalls für deutsche Daten soll überprüft werden, ob mit der ersten Revision die Vorhersagemodelle Güte im Hinblick auf die Vorhersage der Daten zum späteren Veröffentlichungsstand verlieren. Tabelle 6.16 gibt die Ergebnisse der Modelle *I* bis *IV* für die Informationssituation *C* wieder. Die Anpassungsgüte der Modelle hat sich nur unwesentlich verschlechtert. Die Schätzungen der Koeffizienten liegen weitestgehend in dem Bereich, der auch für die Informationssituationen *A* und *B* erreicht wird mit dem Unterschied, dass im MIDAS-Ansatz (Modell *IV*) der C-DAX als Regressor an Signifikanz verliert. Auch für deutsche Daten bleibt festzuhalten, dass die Modelle durch die erste Revision nicht überflüssig werden, sondern auch darüber hinaus zur Verbesserung der Datenqualität beitragen können.

Out-of-Sample-Ergebnisse

Die mittleren quadratischen Abweichungen der Prognosen der Vorhersagemodelle von den tatsächlichen Revisionen nach zwei Jahren finden sich für die Informationssituationen *A* und *B* in Tabelle 6.17. Sofern *B* für ein Modell angenommen wird, ist dies entsprechend indexiert. Im Vergleich zu den USA ist es augenfällig, dass der Abstand zwischen der Variante ohne Modell und den Vorhersagemodellen bedeutend größer ist. Auch Out-of-Sample erklären die Vorhersagemodelle über 50 % der Variation. Wird das Modell *I* als Benchmark gewählt, zeigt sich erneut, dass ein großer Anteil der Revisionen ohne Berücksichtigung anderer makroökonomischer Variablen erklärt bzw. vorhergesagt werden kann.

Das beste Vorhersagemodell ist Modell *IV* unter Informationsset *B*. Wie in Tabelle 6.18 zu sehen ist, findet sich jedoch kein signifikanter Vorsprung gegenüber den anderen Modellen. Die Variante ohne Modell wird offensichtlich von allen anderen Modellen dominiert. Auch hier ist

²¹Die Zinsdifferenz als zusätzlicher Regressor verbessert die Ergebnisse nicht und wird daher in der Ergebnisdarstellung nicht berücksichtigt.

Tabelle 6.15: Vorhersagemodelle für Kurzzeitrevisionen des BSP-Wachstums in Deutschland
gegeben A bzw. B

	I	II	III	IV	III _B	IV _B
con	0,062 0,828	0,175 2,396	0,214 2,889	0,206 3,430	0,225 2,973	0,222 3,280
Q2	0,256 2,086	0,172 1,587	0,147 1,372	0,173 1,763	0,148 1,360	0,145 1,406
Q3	0,328 2,696	0,270 2,500	0,203 1,907	0,254 2,516	0,188 1,727	0,253 2,542
$trev_{t-2}$	-0,764 -2,961	-0,655 -2,843	-0,589 -2,661	-0,698 -3,189	-0,609 -2,706	-0,639 -3,107
$t-1rev_{t-3}$	0,787 2,972	0,772 3,337	0,725 3,183	0,671 3,299	0,671 2,803	0,619 2,850
$t+1y_t$	-0,289 -7,292	-0,368 -9,248	-0,393 -9,887	-0,390 -10,987	-0,392 -9,660	-0,390 -10,695
bc_{t-2}			-0,133 -0,360		-0,187 -0,495	
bc_{t-1}		-0,585 -2,135	-0,789 -1,188		-0,718 -0,967	
bc_t		0,867 3,008	1,404 2,866	1,322 3,476	1,241 1,446	1,258 3,444
bc_{t+1}					-0,042 -0,055	
al_{t-2}			-0,949 -0,758		-1,120 -0,870	
al_{t-1}		-1,475 -2,064	-3,300 -1,593		-3,581 -1,713	
al_t			3,656 1,806	-5,229 -2,616	4,490 1,808	-5,545 -2,750
al_{t+1}					-1,070 -0,400	
dax_{t-2}		0,312 1,390	0,401 1,581		0,517 1,868	
dax_{t-1}		-0,437 -1,972	-0,068 -0,236		-0,232 -0,709	
dax_t			-0,653 -2,294	-1,083 -2,136	-0,422 -1,222	-1,472 -2,723
dax_{t+1}					-0,34 -0,831	
σ^2	0,194	0,147	0,135	0,122	0,139	0,120
R^2	0,547	0,680	0,722	0,691	0,728	0,697
adR^2	0,516	0,634	0,662	0,625	0,653	0,632

HINWEIS Die Tabelle zeigt die Parameterschätzungen der Vorhersagemodelle in der Informationssituation A bzw. B sofern das Modell mit dem Buchstaben B indiziert ist. $t+8y_t - t+1y_t$ ist die Abhängige. Die t -Statistiken sind untergesetzt.

ABKÜRZUNGEN con: Konstante; Q2: Dummy für das zweite Quartal; Q3: Dummy für das dritte Quartal; bc : Ifo-Konjunkturklima; al : monatliche Wachstumsraten der Arbeitslosenzahlen; dax : Vierteljahres-Renditen des C-DAX.

Tabelle 6.16: Vorhersagemodelle für Kurzzeitrevisionen des BSP-Wachstums in Deutschland gegeben C

	I	II	III	IV
con	0,037 0,488	0,153 2,105	0,200 2,648	0,150 2,341
Q2	0,266 2,212	0,182 1,703	0,155 1,450	0,163 1,640
Q3	0,328 2,743	0,272 2,567	0,198 1,846	0,310 3,196
${}_{t+2}rev_t$	-0,502 -1,968	-0,568 -2,517	-0,594 -2,602	-0,530 -2,451
${}_trev_{t-2}$	-0,680 -2,645	-0,577 -2,512	-0,532 -2,360	-0,584 -2,697
${}_{t-1}rev_{t-3}$	0,778 2,993	0,771 3,397	0,684 2,906	0,670 3,025
${}_{t+2}y_t$	-0,275 -6,961	-0,355 -8,967	-0,380 -9,423	-0,351 -9,951
bc_{t-2}			-0,178 -0,480	
bc_{t-1}		-0,582 -2,167	-0,820 -1,120	
bc_t		0,832 2,934	1,354 1,601	1,111 3,166
bc_{t+1}			-0,129 -0,173	
al_{t-2}			-1,493 -1,165	
al_{t-1}		-1,583 -2,251	-3,358 -1,631	
al_t			4,387 1,797	-5,639 -3,435
al_{t+1}			-0,891 -0,339	
dax_{t-2}		0,317 1,438	0,465 1,698	
dax_{t-1}		-0,388 -1,771	-0,131 -0,400	
dax_t			-0,439 -1,292	-0,539 -1,110
dax_{t+1}			-0,237 -0,577	
σ^2	0,187	0,141	0,134	0,119
R^2	0,533	0,671	0,719	0,675
adR^2	0,494	0,617	0,636	0,598

HINWEIS Die Tabelle zeigt die Parameterschätzungen der Vorhersagemodelle in der Informationssituation C . ${}_{t+8}y_t - {}_{t+2}y_t$ ist die Abhängige. Die t -Statistiken sind untergesetzt.

ABKÜRZUNGEN con: Konstante; Q2: Dummy für das zweite Quartal; Q3: Dummy für das dritte Quartal; bc : Ifo-Konjunkturklima; al : monatliche Wachstumsraten der Arbeitslosenzahlen; dax : Vierteljahres-Renditen des C-DAX.

Tabelle 6.17: MSFE – Kurzzeitrevisionen – Deutschland

	rel. zu kein Modell	rel. zu Modell <i>I</i>
kein Modell	1,000	2,342
<i>I_A</i>	0,427	1,000
<i>II_A</i>	0,388	0,910
<i>III_A</i>	0,400	0,937
<i>IV_A</i>	0,385	0,903
<i>III_B</i>	0,413	0,967
<i>IV_B</i>	0,371	0,868

Hinweis: Basierend auf 25 Vorhersagen (${}_{t+8}y_t - {}_{t+1}y_t$). Kein Modell bedeutet, dass Datenrationalität angenommen wird.

Tabelle 6.18: Diebold-Mariano-Test – Kurzzeitrevisionen – Deutschland

	<i>I</i>	<i>II</i>	<i>III</i>	<i>IV</i>	<i>III_B</i>	<i>IV_B</i>
kein Modell	2,040 [‡]	1,710 [‡]	1,680 [‡]	1,716 [‡]	1,587 [‡]	1,882 [‡]
<i>I</i>	–	0,323	0,206	0,331	0,098	0,499
<i>II</i>	–	–	-0,295	0,070	-0,483	0,319
<i>III</i>	–	–	–	0,293	-0,576	0,619
<i>IV</i>	–	–	–	–	-0,472	0,344
<i>III_B</i>	–	–	–	–	–	0,696

Hinweis: Basierend auf 25 Vorhersagen (${}_{t+8}y_t - {}_{t+2}y_t$). Bei nicht-genisteten Modellen liegt ein zweiseitiger Test vor. Die kritischen Werte werden einer *t*-Verteilung mit 24 Freiheitsgraden entnommen. Interpretation: Signifikant positive Werte korrespondieren zu besseren Vorhersagemodellen in den Spalten; signifikant negative Werte korrespondieren zu besseren Vorhersagemodellen in den Zeilen. *: Signifikant zum 10 % Niveau.

Bei genisteten Modellen ist der Test einseitig und es werden die asymptotischen kritischen Werte aus McCracken (1999) entnommen. †: Signifikant zum 10% Niveau. ‡: Signifikant zum 5% Niveau.

Tabelle 6.19: MSFE – Kurzzeitrevisionen nach der ersten Revision (C)– Deutschland

	rel. zu kein Modell	rel. zu Modell I
kein Modell	1,000	2,596
<i>I</i>	0,385	1,000
<i>II</i>	0,329	0,853
<i>III</i>	0,413	1,073
<i>IV</i>	0,478	1,241

Hinweis: Basierend auf 24 Vorhersagen (${}_{t+8}y_t - {}_{t+1}y_t$). Kein Modell bedeutet, dass Datenrationalität angenommen wird.

Tabelle 6.20: Diebold-Mariano-Test – Kurzzeitrevisionen nach der ersten Revision (C)– Deutschland

	<i>I</i>	<i>II</i>	<i>III</i>	<i>IV</i>
kein Modell	1,971 [‡]	1,832 [‡]	1,520 [‡]	1,718 [‡]
<i>I</i>	–	0,480	-0,202	-0,904
<i>II</i>	–	–	-1,859*	-1,563
<i>III</i>	–	–	–	-0,589

Hinweis: Basierend auf 24 Vorhersagen (${}_{t+8}y_t - {}_{t+1}y_t$). Bei nicht-genisteten Modellen liegt ein zweiseitiger Test vor. Die kritischen Werte werden einer t -Verteilung mit 23 Freiheitsgraden entnommen. Interpretation: Signifikant positive Werte korrespondieren zu besseren Vorhersagemodellen in den Spalten; signifikant negative Werte korrespondieren zu besseren Vorhersagemodellen in den Zeilen. *: Signifikant zum 10 % Niveau.

Bei genisteten Modellen ist der Test einseitig und es werden die asymptotischen kritischen Werte aus McCracken (1999) entnommen. †: Signifikant zum 10% Niveau. ‡: Signifikant zum 5% Niveau.

wieder zu berücksichtigen, dass die kritischen Werte einer t -Verteilung mit 24 Freiheitsgraden zu konservativ wären, da die Variante ohne Modell in den anderen genistet ist und somit die kritischen Werte von McCracken (1999) zur Anwendung kommen.

Wird die erste Revision hinzugenommen und die Out-of-Sample-Analyse auf Grundlage der Informationssituation C durchgeführt, zeigen sich analog zu den In-Sample-Ergebnissen keine bedeutenden Verschiebungen im Hinblick auf die Vorhersagbarkeit der Datenrevisionen. Bereits Modell I bringt erhebliche Verbesserungen mit sich. Die erste Revision macht die Modelle nicht obsolet, siehe Tabelle 6.19 für die mittleren quadratischen Fehler. Gewinner der Hinzunahme der ersten Revision ist Modell II . Es weist nun den niedrigsten MSFE aus und ist zum 10 % Niveau signifikant besser als Modell III , siehe Tabelle 6.20.

Revisionen von Wachstumsdaten sind für Stichproben aus den USA und Deutschland vorhersagbar. Es treten jedoch erhebliche Unterschiede auf. In den USA sind die ersten Veröffentlichungen weniger volatil als die revidierten Wachstumsraten. Für Deutschland gilt das Gegenteil, was bereits die Hypothese der Datenrationalität für den deutschen Veröffentlichungsprozess ausschließt. So findet sich auch, dass die Vorhersagemodelle mehr von der Streuung der Revisionen

in Deutschland erklären als in den USA. Schließlich ist es für die USA kaum möglich Vorhersagemodelle zu nutzen um Kurzzeitrevisionen Out-of-Sample vorherzusagen also frühe Veröffentlichungen von Wachstumsdaten in Echtzeit zu verbessern. Insgesamt ist allerdings für die USA festzuhalten, dass der hier vorgeschlagene gemischt frequente Ansatz zu erheblichen Verbesserungen in der Vorhersage von Datenrevisionen verglichen mit den monofrequenten Ansätzen in Faust et al. (2005) oder Fixler und Grimm (2006) führt, die zu einer gesteigerten Datenqualität beitragen können. Basierend auf den Ergebnissen des gemischt frequenten Ansatzes für die USA bietet es sich an, dass für Politikentscheidungen am aktuellen Rand nicht nur die frühen BIP-Veröffentlichungen, sondern auch ein mit diesen operierendes gemischt frequentes Backcasting-Modell Beachtung findet.

Bezogen auf die BIP-Daten der USA zeigt sich, dass es von wesentlichem Vorteil ist, andere Konjunkturindikatoren am aktuellen Rand während und kurz nach der Veröffentlichung der BIP-Daten zu berücksichtigen. Diese Aussage ist für Deutschland nicht gültig. Insbesondere die erste Veröffentlichung selbst hat einen erheblichen Erklärungsgehalt und die im deutschen Fall berücksichtigten Regressoren, zwei von ihnen sind Frühindikatoren, bringen am aktuellen Rand kaum Informationen für spätere Datenrevisionen mit sich. Allerdings ist hier die Datenlage schlechter. Monatliche Daten, die Revisionen unterliegen, fallen gänzlich weg, da sie nicht als Echtzeitdaten für den fraglichen Zeithorizont verfügbar sind. Die Berücksichtigung der Kapazitätsauslastung oder der Industrieproduktion als Regressoren in hoher Frequenz am aktuellen Rand könnte auch für deutsche Daten zu zusätzlichen Verbesserungen führen. Aus besagtem Mangel an Daten bleibt diese Frage an dieser Stelle allerdings offen. Die Ergebnisse aus den USA weisen jedoch in die Richtung, dass eine Untersuchung auf einer entsprechend erweiterten Echtzeitdatenbasis auch für Deutschland erstrebenswert ist.

Kapitel 7

Zusammenfassende Schlussfolgerung

Im Mittelpunkt dieser Arbeit steht die Modellierung und Vorhersage des realen und saisonbereinigten BIP. Dabei geht es nicht darum ein weiteres Vorhersagemodell der bereits umfangreichen Literatur zur Vorhersage des BIP-Wachstums hinzuzufügen, sondern verschiedene Aspekte insbesondere aus der Sicht des deutschen BIP-Wachstums aufzugreifen und zu beleuchten. Dadurch können Einsichten gewonnen werden, auf denen die weitere Diskussion zu BIP-Vorhersagen aufbauen kann.

In Kapitel 2 wird eine Vielzahl von Zeitreihenmodellen an das deutsche BIP-Wachstum angepasst um eine mögliche beste Charakterisierung der Daten zu finden. In-Sample schneidet das Floor-Ceiling-Modell gemessen an der Marginalen Likelihood sehr gut ab, was insbesondere mit der Berücksichtigung der Heteroskedastie in diesem Modell zusammenhängt. Out-of-Sample weist es allerdings sehr schlechte Eigenschaften bezogen auf die Punktprognosen auf. In der Güte der Punktprognosen schneiden die Modelle gut ab, die Zustandsabhängigkeiten der autoregressiven Parameter modellieren, wie das MSA-, das MSAH- oder das SETAR-Modell. Das schlechte Abschneiden einiger Modelle, wie des Bounce-Back-Modells, das für US Daten relativ gute Ergebnisse aufweist, zeigt auch, dass der deutsche Konjunkturverlauf erhebliche Unterschiede zum US Verlauf besitzt.

In Kapitel 3 wird die Analyse der Charakterisierung des BIP-Wachstums durch Zeitreihenmodelle um die Frage erweitert, ob besagte Modelle in der Lage sind die Konjunkturzykluseigenschaften des deutschen BIP-Wachstums nachzubilden. Hier weist insbesondere das DLR-Modell gute Eigenschaften auf. Die Charakterisierung des BIP-Wachstums als Abfolge wechselnder Regime mit stochastischen Niveaus und Trends erscheint gut geeignet den tatsächlichen Konjunkturzyklus zu repräsentieren.

Aus den Kapiteln 2 und 3 kann man schlussfolgern, dass es unter den berücksichtigten kein eindeutig vorzuziehendes Zeitreihenmodell im Sinne eines besten Modells zu Beschreibung und Vorhersage des deutschen BIP-Wachstums gibt. Ein einfaches lineares Modell erscheint jeden-

falls nicht hinreichend. Viele der Ergebnisse und die Eigenschaften des DLR-Modells weisen daraufhin, dass die Konjunkturmuster einem steten Wandel unterliegen und auch wenn das DLR-Modell Out-of-Sample nicht überzeugen konnte, erscheinen lokale Modelle zur Vorhersage sinnvoll.

Anschließend an die Diskussion verschiedener Zeitreihenmodelle für die Wachstumsraten des BIP in den Kapiteln 2 und 3 werden in Kapitel 4 die Wachstumsraten des deutschen BIP explizit auf die Existenz eines Bruchs in der Volatilität untersucht. Es findet sich eindeutige Evidenz für eine permanente Reduktion der Volatilität in den frühen 90er Jahren, die insbesondere auf den im Zuge der Wiedervereinigung beschleunigten Strukturwandel zurückzuführen ist.

Zeitliche Instabilität ist ebenfalls im Fokus von Kapitel 5. Zum einen kann bestätigt werden, dass die Vorlaufeigenschaften der Zinsdifferenz zum BIP-Wachstum in Deutschland und den USA Schwankungen unterliegt. Ferner wird in Kapitel 5 nachgewiesen, dass der Erklärungsansatz, der die Schwankungen der Vorlaufeigenschaften auf Schwankungen der Geldpolitik zurückführt, nicht geeignet ist das Phänomen der Instabilität der Vorlaufeigenschaften der Zinsdifferenz vollständig zu erklären. Die Konjunkturvorhersage mit Frühindikatoren unterliegt folglich ähnlichen Problemen, wie die Anwendung von Zeitreihenmodellen. Die Zusammenhänge unterliegen Schwankungen in der Zeit, die selber kaum vorhergesehen bzw. im Hinblick auf die Zinsdifferenz nicht vollständig mit ökonomischen Modellen erklärt werden können.

Schließlich greift die Arbeit ein Problem auf, das für die Arbeit mit dem BIP bzw. seinem Wachstum insbesondere bei der Anwendung von Vorhersagemodellen am aktuellen Rand von Bedeutung ist. Die frühen Veröffentlichungen des BIP-Wachstums unterliegen zum Teil erheblichen Revisionen. In dieser Arbeit wird gezeigt, dass für die USA die Anwendung gemischt frequenter Verfahren, die auch monatliche Informationen berücksichtigen, zu erheblichen Verbesserungen der Vorhersagbarkeit der Datenrevisionen führt. Für deutsche Daten bieten bereits gleich-frequente Modelle gute Vorhersagen der Datenrevisionen, wobei die Echtzeitdatenlage im Bezug auf monatliche Kovariate erheblich schlechter ist verglichen mit den USA. Allgemein kann man die Ergebnisse dahingehend interpretieren, dass das BIP am aktuellen Rand als Zielvariable mit entsprechender Vorsicht zu behandeln ist und zumindest vergleichend "Backcasting"-Modelle zur Gewinnung einer verbesserten Zielvariablen eingesetzt werden sollten, wobei die "Backcasting"-Modelle die frühen Veröffentlichungen der Daten mit berücksichtigen.

Die Vorhersage des BIP-Wachstums steht einer Vielzahl von Problemen gegenüber, die letztlich mit der Komplexität des Konjunkturphänomens zusammenhängen und sich unter anderem in zeitlichen Instabilitäten der Modelle zur Charakterisierung und Vorhersage des BIP äußern. Trotzdem oder vielleicht gerade deswegen ist eine intensiviertere Analyse und Anwendung von Vorhersagemodellen des BIP anzuraten. Zum einen erscheint eine intensiviertere Analyse notwendig um die Qualität der Vorhersagen ständig zu überprüfen, zum anderen hat diese Arbeit aufgezeigt, dass die Methoden, die in Vorhersagemodellen des BIP eine Rolle spielen, nicht nur

genutzt werden können, Erwartungen über die zukünftige konjunkturelle Entwicklung zu bilden, sondern auch zu einer besseren Bestimmung des jeweils jüngsten bzw. aktuellen Konjunkturverlaufs geeignet sind.

Anhang A

Methoden

A.1 Hamilton-Filter und Kim-Glätter

In der folgenden Darstellung sei $\{Y_t\}_{t=1}^T$ eine Zeitreihe eines Skalars oder eines Vektors endogener Variablen. Exogene Variablen sowie die Parameter des Modells, auf die die Verteilung von $\{Y_t\}_{t=1}^T$ bedingt wird, werden in der folgenden Darstellung weggelassen bzw. sind immer implizit Bedingungen. Der unbeobachtbare Zustand sei $\{s_t\}_{t=1}^T$, von dem angenommen wird, dass er einem Markov-Prozess mit $M + 1$ verschiedenen Zuständen folgt (also kann s_t ganzzahlige Werte zwischen 0 und M annehmen), und der die bedingte Verteilung von $\{Y_t\}_{t=1}^T$ beeinflusst. Der Hamilton-Filter ermöglicht es, die Wahrscheinlichkeit der Zustände zum Zeitpunkt t gegeben die Informationen bis zum Zeitpunkt t zu berechnen. Der Filter muss im Zeitpunkt $t = 0$ initialisiert werden. In der Regel geschieht dies, indem man für die bedingte Wahrscheinlichkeit $P[s_0|Y_0, \Theta]$ die unbedingte Wahrscheinlichkeit $P[s_0]$ einsetzt. Vergleicht man die folgende Darstellung mit der in Hamilton (1989) für das MSM-Modell mit einer beliebigen Anzahl der Verzögerten als Regressoren, zeigt sich, dass dort die Zustandsvariable zwar nur zwei Werte annehmen kann, dafür aber entsprechend der Anzahl der Verzögerten k auf bis hin zu k vergangene Werte der Zustandsvariable bedingt wird. Die höhere Anzahl von Verzögerten im MSM-Modell lässt sich durch eine höhere Anzahl an diskreten Zuständen abbilden. Wird dies berücksichtigt, entspricht die Darstellung hier der in Hamilton (1989).

Hamilton-Filter

Der Hamilton-Filter ist ein iteratives Verfahren, welches ermöglicht die Zustandswahrscheinlichkeiten zum Zeitpunkt t bedingt auf die Beobachtungen bis zum Zeitpunkt t sowie die Parameter zu ermitteln. Für jeden Punkt in der Zeit wird der Hamilton-Filter einmal durchlaufen.

F I Im ersten Schritt wird aus dem Ergebnis des Filters der vorhergehenden Zeitpunkte, also

der gefilterten Zustandswahrscheinlichkeiten in $t-1$ und den Übergangswahrscheinlichkeiten, die gemeinsamen Zustandswahrscheinlichkeiten in den Zeitpunkten t und $t-1$ gegeben die Beobachtungen bis zum Zeitpunkt $t-1$ berechnet:

$$P \left[s_t, s_{t-1} | \{Y_{\tilde{t}}\}_{\tilde{t}=1}^{t-1} \right] = P [s_t | s_{t-1}] \cdot P \left[s_{t-1} | \{Y_{\tilde{t}}\}_{\tilde{t}=1}^{t-1} \right],$$

wobei $P[s_t | s_{t-1}]$ die Übergangs- bzw. Bleibewahrscheinlichkeit darstellt und selber weiter parametrisiert werden kann, vgl. Filardo (1994).

F II Das Ergebnis aus F I wird mit der auf die eigene Vergangenheit und die Zustände bedingten Wahrscheinlichkeitsdichtefunktion der Beobachtung zum Zeitpunkt t multipliziert:

$$f \left(Y_t, s_t, s_{t-1} | \{Y_{\tilde{t}}\}_{\tilde{t}=1}^{t-1} \right) = f \left(Y_t | s_t, s_{t-1}, \{Y_{\tilde{t}}\}_{\tilde{t}=1}^{t-1} \right) \cdot P \left[s_t, s_{t-1} | \{Y_{\tilde{t}}\}_{\tilde{t}=1}^{t-1} \right]$$

wobei für $f(Y_t | s_t, s_{t-1}, \{Y_{\tilde{t}}\}_{\tilde{t}=1}^{t-1})$ in der Regel eine Normalverteilung unterstellt wird, siehe zum Beispiel Gleichung 2.7. Andere Verteilungen wie die t -Verteilung sind ebenfalls denkbar, siehe unter anderem Hamilton (2005).

F III Indem über die Zustände integriert wird, wird die ausschließlich auf die eigene Vergangenheit bedingte Wahrscheinlichkeitsdichtefunktion der Beobachtung in t gewonnen:

$$f \left(Y_t | \{Y_{\tilde{t}}\}_{\tilde{t}=1}^{t-1} \right) = \sum_{s_t=0}^M \sum_{s_{t-1}=0}^M f \left(Y_t, s_t, s_{t-1} | \{Y_{\tilde{t}}\}_{\tilde{t}=1}^{t-1} \right).$$

Da sich die Likelihood-Funktion als Produkt der entsprechend bedingten Dichten ergibt, kann über F III der Wert der Likelihood-Funktion mit Hilfe des Hamilton-Filters errechnet werden.

F IV Es werden die auf die Beobachtung in t bedingten Wahrscheinlichkeiten der Zustände gewonnen:

$$P \left[s_t, s_{t-1} | \{Y_{\tilde{t}}\}_{\tilde{t}=1}^t \right] = \frac{f \left(Y_t, s_t, s_{t-1} | \{Y_{\tilde{t}}\}_{\tilde{t}=1}^{t-1} \right)}{f \left(Y_t | \{Y_{\tilde{t}}\}_{\tilde{t}=1}^{t-1} \right)}$$

F V und, indem über die Zustände in $t-1$ integriert wird, schließlich die gefilterte Wahrscheinlichkeit der Zustände:

$$P \left[s_t | \{Y_{\tilde{t}}\}_{\tilde{t}=1}^t \right] = \sum_{s_{t-1}=0}^M P \left[s_t, s_{t-1} | \{Y_{\tilde{t}}\}_{\tilde{t}=1}^t \right].$$

Nach F V wird t um eins erhöht und basierend auf dem Ergebnis von F V setzt der Filter wieder bei F I ein.

Kim-Glätter

Bereits Hamilton (1990) hat einen Glätter vorgeschlagen, der jedoch von Kim (1994) basierend auf der Markov-Eigenschaft bedeutend vereinfacht wurde. Geglättete Wahrscheinlichkeiten geben die volle Stichprobeninformation über die Zustände wieder. Sie spielen bei der Anwendung des EM-Algorithmus in der Maximum-Likelihood-Schätzung von Markov-Switching-Modellen eine zentrale Rolle, da über den Glätter die basierend auf der gesamten Stichprobeninformation erwarteten Zustandswahrscheinlichkeiten gewonnen werden. Der Glätter kann als eine Art rekursiver Filter aufgefasst werden. Die Stichprobe wird in die Gegenrichtung also von T bis 1 durchlaufen, wobei der letzte Wert des Filters $P[s_T|\{Y_{\tilde{t}}\}_{\tilde{t}=1}^T, \Theta]$ der erste Wert des Glätters ist.

G I In diesem Schritt wird die Ein-Schritt-Prognosewahrscheinlichkeit der Zustände berechnet

$$P[s_{t+1}|\{Y_{\tilde{t}}\}_{\tilde{t}=1}^t] = \sum_{s_t=0}^M P[s_{t+1}|s_t] P[s_t|\{Y_{\tilde{t}}\}_{\tilde{t}=1}^t],$$

die in den eigentlichen Glätter (G II) eingeht.

G II

$$P[s_t|\{Y_{\tilde{t}}\}_{\tilde{t}=1}^T] = \sum_{s_{t+1}=0}^M \frac{P[s_{t+1}|s_t] P[s_t|\{Y_{\tilde{t}}\}_{\tilde{t}=1}^t]}{P[s_{t+1}|\{Y_{\tilde{t}}\}_{\tilde{t}=1}^t]} P[s_{t+1}|\{Y_{\tilde{t}}\}_{\tilde{t}=1}^T]$$

Im eigentlichen Glätter werden die Ein-Schritt-Prognose-Wahrscheinlichkeiten aus G I, die gefilterten Wahrscheinlichkeiten aus F V sowie der vorausgehende Wert ($t + 1$ wegen der rekursiven Struktur des Glätters) von G II zusammengefasst.

A.2 Gibbs-Sampler der Zeitreihenmodelle

AR-Modell

Die Parameter μ und $\{\phi_\ell\}_{\ell=1}^k$ werden zu einem Block zusammengefasst. Der zweite Block umfasst nur die Varianz σ^2 bzw. die Präzision $\tau = 1/\sigma^2$. Es wird ein unabhängiger Normal-Gamma-Prior angenommen.¹ Die a priori Verteilung des ersten Blocks wird wie folgt angenommen:

$$\mu, \{\phi_\ell\}_{\ell=1}^k \sim N(\mu^p, \Omega^p),$$

wobei μ^p ein Vektor der Länge $k + 1$ ist und Ω^p eine Diagonalmatrix der Form $I \cdot \sigma^{2p}$ ist. Für die Präzision wird eine Gammaverteilung angenommen:

$$\tau \sim \text{Gam}(\lambda^p, \kappa^p).$$

¹Die Prior werden in der Form den Verteilungsfamilien gewählt, dass die vollständig bedingten Verteilungen der gleichen Verteilung wie die Prior folgen. Sie sind in diesem Sinne konjugiert. Dieses Prinzip wird für alle Parameter angewendet.

Im Gibbs-Sampler wird iterativ aus den folgenden vollständig bedingten Verteilungen gezogen:²

- $\mu, \{\phi_\ell\}_{\ell=1}^k | y, \tau \sim N \left((X'\Omega^{-1}X + \Omega^{p-1})^{-1} (X'\Omega^{-1}y + \Omega^{p-1}\mu^p); \tau^{-1} (X'\Omega^{-1}X + \Omega^{p-1})^{-1} \right)$,
wobei die Matrix X eine Konstante und die verzögerten Werte des BIP-Wachstums enthält und Ω eine Diagonalmatrix mit $1/\tau$ auf der Diagonalen ist. An dieser Stelle und im Folgenden steht y für den gesamten Vektor der beobachtbaren BIP-Wachstumsraten, also $y = \{y_t\}_{t=1}^T$.
- $\tau | \mu, \{\phi_\ell\}_{\ell=1}^k, y \sim \text{Gam}(\lambda^p + \sum_t \hat{\epsilon}_t^2/2, \kappa^p + T/2)$,
wobei $\hat{\epsilon}_t$ die Residuen bezeichnet.

Die Werte der Hyperparameter sind in Tabelle A.1 für neun verschiedene Szenarien zu finden. Es handelt sich dabei um Hyperparameter, die in allen Modellen auftreten. Die Werte modellspezifischer Hyperparameter werden bei der Erläuterung der jeweiligen Gibbs-Sampler angegeben.

MSA- und MSI-Modell

Der erste Block umfasst die Parameter μ_1, μ_2 und $\{\phi_\ell\}_{\ell=1}^k$ im MSI-Modell und $\mu, \{\phi_{1,\ell}\}_{\ell=1}^k$ sowie $\{\phi_{2,\ell}\}_{\ell=1}^k$ im MSA-Modell. Der entsprechende Block von Parametern wird im Folgenden, sofern nicht von einzelnen Parametern aus diesem Block die Rede ist, als $\Theta_{\mu,\phi}$ aufgeführt. Der zweite Block ist analog zum AR-Modell. Für beide Blöcke werden die gleichen a priori Verteilungen wie im AR-Modell angenommen. Zusätzlich bilden die Übergangs- bzw. Bleibewahrscheinlichkeiten p_{11} und p_{22} einen dritten Block. A priori sind p_{11} und p_{22} Beta-verteilt mit den Parametern v^p und w^p , die für alle MS-Modelle in Kapitel 2 auf 6 bzw. 2 gesetzt werden. Die Zustandsvariablen $\{s_t\}_{t=1}^T$ werden als fehlende Daten aufgefasst und im Rahmen der Gibbs-Samplers imputiert, so dass die Verteilungen der Parameter auf $\{s_t\}_{t=1}^T$ bedingt werden können. Im Gibbs-Sampler wird iterativ aus den folgenden vollständig bedingten Verteilungen gezogen:

- $\Theta_{\mu,\phi} | y, \tau, \{s_t\}_{t=1}^T \sim N \left((X'\Omega^{-1}X + \Omega^{p-1})^{-1} (X'\Omega^{-1}y + \Omega^{p-1}\mu^p), (X'\Omega^{-1}X + \Omega^{p-1})^{-1} \right)$,
wobei die Matrix X im MSI-Modell die Zustandsvariable $\{s_t\}_{t=1}^T$ und $1 - \{s_t\}_{t=1}^T$ sowie die verzögerten Werte des BIP-Wachstums enthält. Im MSA-Modell besteht X aus einer Konstanten und zweimal den verzögerten Werten des BIP-Wachstums, die mit $\{s_t\}_{t=1}^T$ bzw. $1 - \{s_t\}_{t=1}^T$ elementweise multipliziert worden sind.
- $\tau | \Theta_{\mu,\phi}, y, \{s_t\}_{t=1}^T \sim \text{Gam}(\lambda^p + \sum_t \hat{\epsilon}_t^2/2, \kappa^p + T/2)$
- $p_{11} | \{s_t\}_{t=1}^T \sim \text{Beta}(n_{11} + v^p, n_{12} + w^p)$
- $p_{22} | \{s_t\}_{t=1}^T \sim \text{Beta}(n_{22} + v^p, n_{21} + w^p)$,

²Es werden in der Darstellung nur die Bedingungen aufgeführt, die Einfluss auf die Verteilungen haben.

wobei n_{ii} die Anzahl der Perioden angibt, in denen der Zustand i andauert, und n_{ij} die Anzahl der Perioden, in denen der Zustand von i nach j wechselt.

- Die Zustandsvariable $\{s_t\}_{t=1}^T$ wird als fehlende Daten aufgefasst und in jedem Gibbs-Zug imputiert. Allgemein gilt für die Verteilung dieser diskreten Variable

$$P(\{s_t\}_{t=1}^T|y, \Theta) = P(s_T|y, \Theta) \prod_{t=1}^{T-1} P(s_t|\{s_{\bar{t}}\}_{\bar{t}=t+1}^T, y, \Theta),$$

wobei wegen der Markov-Eigenschaft $P(s_t|\{s_{\bar{t}}\}_{\bar{t}=t+1}^T, y, \Theta) = P(s_t|s_{t+1}, y, \Theta)$ ist; ferner gilt $P(s_t|s_{t+1}, y, \Theta) = P(s_t|s_{t+1}, \{y_{\bar{t}}\}_{\bar{t}=1}^t, \Theta)$, weil s_t mit zukünftigen Werten nur über s_{t-1} abhängt ebenfalls wegen der Markov-Eigenschaft, so dass

$$\{s_t\}_{t=1}^T|y, \Theta \sim P(s_T|y, \Theta) \prod_{t=1}^{T-1} P(s_t|s_{t+1}, \{y_{\bar{t}}\}_{\bar{t}=1}^t, \Theta).$$

Aus dieser Verteilung kann nach dem Multi-Move-Verfahren gezogen werden.³ Mit Hilfe des Hamilton-Filters wird $P(s_T|y, \Theta)$ bestimmt. Es wird aus einer (0,1)- Gleichverteilung eine Zahl gezogen und s_T gleich 1 gesetzt, wenn die gezogene Zahl kleiner ist als $P(s_T|y, \Theta)$. Dann wird von $t = T - 1$ bis $t = 1$ wie folgt iteriert. Es wird

$$P(s_t|s_{t+1}, \{y_{\bar{t}}\}_{\bar{t}=1}^t, \Theta) = \frac{P(s_{t+1}|s_t)P(s_t|\{y_{\bar{t}}\}_{\bar{t}=1}^t, \Theta)}{P(s_{t+1}|\{y_{\bar{t}}\}_{\bar{t}=1}^t, \Theta)}$$

berechnet, wobei die entsprechenden Ausdrücke aus dem Hamilton-Filter gewonnen werden können.⁴ Es werden jeweils Zufallszahlen aus einer (0,1)- Gleichverteilung gezogen um diskrete Werte für s_t zu imputieren. Dabei werden die Zufallszahlen mit der zuvor beschriebene Wahrscheinlichkeit verglichen und je nachdem welcher Wert größer ist eine 0 oder eine 1 imputiert.

MSAH- und MSIH-Modell

Im Wesentlichen ist der Gibbs-Sampler identisch zu dem der MSA- und MSI-Modelle. Durch die Zustandsabhängigkeit der Varianz sind zwei Änderungen zu berücksichtigen. Zum einen tritt eine zweite Varianz dazu. Außerdem muss die Heteroskedastie bei den Zügen der Mittelwertparameter berücksichtigt werden.

³Dieses wird von Shephard (1994) sowie Carter und Kohn (1994) vorgeschlagen. Eine anschauliche Darstellung findet sich in Krolzig (1997). Alternativ existiert das Single-Move-Verfahren von Albert und Chib (1993b), in dem die für die Züge verwendete Verteilung von s_t auf die zukünftigen und vergangenen Realisationen der Zustandsvariablen bedingt wird.

⁴ $P(s_t|\{y_{\bar{t}}\}_{\bar{t}=1}^t, \Theta)$ ist die gefilterte Wahrscheinlichkeit für den Zustand s_t und $P(s_{t+1}|\{y_{\bar{t}}\}_{\bar{t}=1}^t, \Theta)$ ist die prognostizierte.

- $\Theta_{\mu,\phi}|y, \tau, \{s_t\}_{t=1}^T \sim N((X'\Omega^{-1}X + \Omega^{p-1})^{-1}(X'\Omega^{-1}y + \Omega^{p-1} \cdot \mu^p); (X'\Omega^{-1}X + \Omega^{p-1})^{-1})$,
wobei die Diagonalmatrix Ω auf der Diagonalen entweder $1/\tau_1$ oder $1/\tau_2$ entsprechend der Zustandsvariablen $\{s_t\}_{t=1}^T$ hat.
- $\tau_1|\mu_1, \{\phi_{1,\ell}\}_{\ell=1}^k, y, \{s_t\}_{t=1}^T \sim \text{Gam}(\lambda^p + \sum_t s_t \hat{\epsilon}_t^2/2, \kappa^p + \sum_t s_t/2)$
- $\tau_2|\mu_2, \{\phi_{2,\ell}\}_{\ell=1}^k, y, \{s_t\}_{t=1}^T \sim \text{Gam}(\lambda^p + \sum_t (1-s_t) \hat{\epsilon}_t^2/2, \kappa^p + \sum_t (1-s_t)/2)$
- $p_{11}|\{s_t\}_{t=1}^T \sim \text{Beta}(n_{11} + v^p, n_{12} + w^p)$
- $p_{22}|\{s_t\}_{t=1}^T \sim \text{Beta}(n_{22} + v^p, n_{21} + w^p)$,
wobei n_{ii} die Anzahl der Perioden angibt, in denen der Zustand i andauert, und n_{ij} die Anzahl der Perioden, in denen der Zustand von i nach j wechselt.
- $\{s_t\}_{t=1}^T|y, \Theta \sim P(s_T|y, \Theta) \prod_{t=1}^{T-1} P(s_t|s_{t+1}, \{y_t\}_{t=1}^t, \Theta)$

SETAR-Modell

Das SETAR-Modell bedingt auf den Schwellenparameter r und die Verzögerung q kann in zwei lineare Modelle geteilt werden. Jeweils kann der für das AR-Modell beschriebene Gibbs-Sampler verwendet werden, wobei der Vektor y und die Matrix X an die entsprechende Aufteilung der Stichprobe anzupassen ist (y_1, X_1 und y_2, X_2). Die vollständig bedingten Verteilungen sind:

- $\mu_1, \{\phi_{1,\ell}\}_{\ell=1}^k|y_1, \tau_1$
 $\sim N((X'_1\Omega_1^{-1}X_1 + \Omega^{p-1})^{-1}(X'_1\Omega_1^{-1}y_1 + \Omega^{p-1}\mu^p); (X'_1\Omega_1^{-1}X_1 + \Omega^{p-1})^{-1})$,
- $\mu_2, \{\phi_{2,\ell}\}_{\ell=1}^k|y_2, \tau_2$
 $\sim N((X'_2\Omega_2^{-1}X_2 + \Omega^{p-1})^{-1}(X'_2\Omega_2^{-1}y_2 + \Omega^{p-1}\mu^p); (X'_2\Omega_2^{-1}X_2 + \Omega^{p-1})^{-1})$,

wobei die Matrix X_1 bzw. X_2 eine Konstante und die verzögerten Werte des BIP-Wachstums enthält und Ω_1 eine Diagonalmatrix mit $1/\tau_1$ bzw. Ω_2 eine Diagonalmatrix mit $1/\tau_2$ auf der Diagonalen ist. Dadurch, dass jeweils auf y_1 und X_1 sowie auf y_2 und X_2 bedingt wird, wird implizit auch auf r und q bedingt. Es werden für beide Zustände die gleichen a priori Verteilungen angenommen.

- $\tau_1|\mu_1, \{\phi_{1,\ell}\}_{\ell=1}^k, y_1 \sim \text{Gam}(\lambda^p + \sum_{t_1} \hat{\epsilon}_t^2/2, \kappa^p + T_1/2)$
- $\tau_2|\mu_2, \{\phi_{2,\ell}\}_{\ell=1}^k, y_2 \sim \text{Gam}(\lambda^p + \sum_{t_2} \hat{\epsilon}_t^2/2, \kappa^p + T_2/2)$

Das Ergebnis des Gibbs-Samplers dient zur Berechnung der a posteriori Verteilung bedingt auf r und q . Die Marginale Likelihood wird dann durch Integration über beide Parameter gewonnen.⁵ Der Gibbs-Sampler wird also für alle Kombinationen aus r und q mit entsprechenden

⁵Chen und Lee (1995) bedingen den Gibbs-Sampler nicht auf r und q , sondern ziehen diese Parameter mit Hilfe des Metropolis-Hastings-Algorithmus im Rahmen des Gibbs-Samplers mit, um entsprechende Bayes-Schätzer für

Anpassungen von y_1 und X_1 sowie y_2 und X_2 wiederholt. Es wird a priori angenommen, dass q die Werte 1 bis 4 mit gleicher Wahrscheinlichkeit annehmen kann. Für r wird a priori eine stetige Gleichverteilung unterstellt. Einfluss auf die Likelihood haben verschiedene Werte von r jedoch nur im Hinblick auf die endliche Anzahl von Ausprägungen der Schwellenvariablen, so dass die Integration über r als gewichtetes arithmetisches Mittel interpretiert werden kann. Die Marginale Likelihood ergibt sich als:

$$f(y) = \frac{1}{4} \sum_{q=1}^4 \sum_{i=[0,1T]}^{[0,9T]} h(r_i) \frac{L(\Theta_{/r,q}|y, r_i, q) p(\Theta_{/r,q})}{p(\Theta_{/r,q}|y, r_i, q)},$$

wobei $\Theta_{/r,q}$ alle Parameter des Modells ohne r und q bezeichnet. Wenn r Werte im Intervall zwischen zwei (geordneten) Ausprägungen der Schwellenvariablen $y_{t-q}^{(i)}$ und $y_{t-q}^{(i+1)}$ annimmt, wirkt dies auf die Likelihood genauso, wie wenn r den Wert der kleineren der beiden Ausprägungen der Schwellenvariable annimmt, also $r_i = y_{t-q}^{(i)}$. Wegen der unterstellten Gleichverteilung entspricht die relative Intervalllänge dem Gewicht $h(r_i)$.

Floor-Ceiling-Modell

Analog zum SETAR-Modell tritt auch im Floor-Ceiling-Modell ein unbeobachtbarer Schwellenparameter auf. Der Gibbs-Sampler ist folglich bedingt auf r_F . Da anhand der ML-Schätzungen eine vereinfachte Varianzspezifikation der ursprünglich von Pesaran und Potter (1997) vorgeschlagenen für deutsche Daten vorgezogen wird, wird der Gibbs-Sampler für diese vorgestellt. Hier wird also $h_t(\gamma, \sigma) = \sigma_1(1 - C_{t-1}) + \sigma_2 C_{t-1}$ unterstellt, vergleiche mit Gleichung 2.11.

- $\mu, \{\phi_\ell\}_{\ell=1}^k, \nu_1, \nu_2 | y, \tau_1, \tau_2, r_F, r_C$
 $\sim N((X'\Omega^{-1}X + \Omega^{p-1})^{-1}(X'\Omega^{-1}y + \Omega^{p-1}\mu^p); (X'\Omega^{-1}X + \Omega^{p-1})^{-1}),$

wobei die Matrix X eine Konstante, die verzögerten Werte des BIP-Wachstums sowie $\{CDR_{t-1}\}_{t=1}^T$ und $\{HC_{t-1}\}_{t=1}^T$ enthält. $\{CDR_{t-1}\}_{t=1}^T$ hängt dabei vom Schwellenparameter r_F ab, über den zu integrieren ist. r_C wird auf die mittlere Wachstumsrate gesetzt. Ω ist eine Diagonalmatrix mit $1/\tau_1$ bzw. $1/\tau_2$ auf der Diagonalen.

- $\tau_1 | y, \mu, \{\phi_\ell\}_{\ell=1}^k, \nu_1, r_F, r_C \sim \text{Gam}(\lambda^p + \sum_{C_{t-1}=0} \hat{\epsilon}_t^2/2, \kappa^p + \sum_t 1(C_{t-1} = 0)/2)$
- $\tau_2 | y, \mu, \{\phi_\ell\}_{\ell=1}^k, \nu_1, \nu_2, r_F, r_C \sim \text{Gam}(\lambda^p + \sum_{C_{t-1}=1} \hat{\epsilon}_t^2/2, \kappa^p + \sum_t 1(C_{t-1} = 1)/2)$

die Parameter zu erzeugen. Bei der Berechnung der Marginalen Likelihood würde ein solches Vorgehen implizieren, dass das von Chib und Jeliazkov (2001) beschriebene Vorgehen verwendet werden muss. Der hier verwendete Ansatz r und q herauszuintegrieren, der auch von Koop und Potter (1999) verwendet wird, erscheint weniger rechenintensiv als der Weg, der auf dem Vorgehen von Chen und Lee (1995) und Chib und Jeliazkov (2001) basiert, und wird daher an dieser Stelle vorgezogen.

Der Schwellenparameter r_F wird analog zum Schwellenparameter r des SETAR-Modells behandelt, wobei die a priori Gleichverteilung nicht zwischen dem 10% und dem 90% Quantil, sondern zwischen dem 10% Quantil und null angenommen wird.

DLR-Modell

Im DLR-Modell existieren drei latente Prozesse, die Zustandsvariable $\{r_t\}_{t=1}^T$ bzw. die korrespondierenden Regimewechselpunkte sowie die Koeffizienten der lokalen Trends $\{a_j\}_{j=1}^J$ und $\{b_j\}_{j=1}^J$. Der Gibbs-Sampler wird bedingt auf $\{r_t\}_{t=1}^T$, während $\{a_j\}_{j=1}^J$ und $\{b_j\}_{j=1}^J$ imputiert werden. Der Parameter δ wird gesetzt ($\delta = 0,575$). Folgende a priori Verteilungen werden angenommen:

- $\nu, \gamma \sim N(\mu^p, \Omega^p)$ mit $\Omega^p = I \cdot \sigma^{2p}$
- $1/\sigma^2$ bzw. $\tau \sim Gam(\lambda^p, \kappa^p)$
- $\mu_{a,1} \sim N(\mu_{a,1}^p, \sigma_a^{2p})$ mit $\mu_{a,1}^p = \mu^p$ und $\sigma_a^{2p} = \sigma^{2p}$
- $\mu_{a,2} \sim N(\mu_{a,2}^p, \sigma_a^{2p})$ mit $\mu_{a,2}^p = 3$
- $\mu_b \sim N(\mu_b^p, \sigma_b^{2p})$ mit $\mu_b^p = -0,1$ und $\sigma_b^{2p} = 1$
- $1/\sigma_a^2 \sim Gam(\lambda_a^p, \kappa_a^p)$ mit $\lambda_a^p = 1$ und $\kappa_a^p = 1$
- $1/\sigma_b^2 \sim Gam(\lambda_b^p, \kappa_b^p)$ mit $\lambda_b^p = 1$ und $\kappa_b^p = 1$
- $\beta_0, \beta_1 \sim N(\mu_\beta^p, \omega_\beta^p)$ mit $\mu_\beta^p = \mu^p$ und $\omega_\beta^p = \sigma^{2p} I$

An dieser Stelle werden $\mu_{a,1}$ und $\mu_{a,2}$ unterschieden, wobei angenommen wird, dass $\mu_{a,2}$ der Erwartungswert der a_j ist, sofern j ein sich beschleunigendes Wachstumsregime ist und $\mu_{a,1}$ wird im gegenteiligen Fall unterstellt. Es ergeben sich folgende vollständig bedingte Verteilungen:

- $\nu, \gamma | y, \{r_t\}_{t=1}^T, \{a_j\}_{j=1}^J, \{b_j\}_{j=1}^J, \tau$
 $\sim N((X'\Omega^{-1}X + \Omega^{p-1})^{-1}(X'\Omega^{-1}y + \Omega^{p-1}\mu^p); (X'\Omega^{-1}X + \Omega^{p-1})^{-1}),$

wobei die Matrix X das verzögerte BIP-Wachstum und den verzögerten Spannungsindex umfassen.

- $\tau | y, \{r_t\}_{t=1}^T, \{a_j\}_{j=1}^J, \{b_j\}_{j=1}^J, \nu, \gamma \sim Gam(\lambda^p + \sum_t \tilde{\epsilon}_t^2/2, \kappa^p + T/2)$
- $\mu_{a,1} | \{a_{j_1}\}_{j_1=1}^{J_1} \sim N((1/\sigma_{a,1}^{2p} + J_1/\sigma_a^2)^{-1}(\mu_{a,1}^p/\sigma_{a,1}^{2p} + J_1\bar{a}_{j_1}/\sigma_a^2), (1/\sigma_{a,1}^{2p} + J_1/\sigma_a^2)^{-1})$, wobei J_1 die Anzahl an kontraktiven Regimen und a_{j_1} ein Parameter des kontraktiven Regimes j_1 ist. Die expansiven Regime werden mit dem Index j_2 gezählt. Es gilt $J_1 + J_2 = J$. Der Ausdruck \bar{a}_{j_1} bezeichnet das arithmetische Mittel der $\{a_{j_1}\}_{j_1=1}^{J_1}$. Analog bezeichnen \bar{a}_{j_2} und \bar{b}_{j_2} ebenfalls arithmetische Mittel.

- $\mu_{a,2}|\{a_{j_2}\}_{j_2=1}^{J_2} \sim N((1/\sigma_{a,2}^{2p} + J_2/\sigma_a^2)^{-1}(\mu_{a,2}^p/\sigma_{a,2}^{2p} + J_2\bar{a}_{j_2}/\sigma_a^2), (1/\sigma_{a,2}^{2p} + J_2/\sigma_a^2)^{-1})$
- $\mu_b|\{b_j\}_{j=1}^J \sim N((1/\sigma_b^{2p} + J/\sigma_b^2)^{-1}(\mu_b^p/\sigma_b^{2p} + J\bar{\ln b}_j/\sigma_b^2), (1/\sigma_b^{2p} + J/\sigma_b^2)^{-1})$
- $1/\sigma_a^2|\{a_j\}_{j=1}^J, \mu_{a,1}, \mu_{a,2} \sim \text{Gam}(\lambda_a^p + (\sum_{j_1}(a_{j_1} - \mu_{a,1})^2 + \sum_{j_2}(a_{j_2} - \mu_{a,2})^2)/2, \kappa_a^p + J/2)$
- $1/\sigma_b^2|\{b_j\}_{j=1}^J, \mu_b \sim \text{Gam}(\lambda_b^p + (\sum_j(\ln b_j - \mu_b)^2)/2, \kappa_b^p + J/2)$
- Die zufälligen Koeffizienten $\{a_j\}_{j=1}^J$ und $\{b_j\}_{j=1}^J$ werden im Rahmen des Gibbs-Samplers imputiert. Die einzelnen Elemente von $\{a_j\}_{j=1}^J$ werden dabei aus der folgenden vollständig bedingten Verteilung gezogen:

$$N\left((\omega_{a_j})^{-1}\left(\mu_{a,(r_t(j)+3)/2}/\sigma_a^2 + \sum_{t=t(j-1)+1}^{t(j)} \tilde{\epsilon}_t/\sigma^2\right), (\omega_{a_j})^{-1}\right),$$

wobei $\omega_{a_j} = 1/\sigma_a^2 + (t(j) - t(j-1))/\sigma^2$ und $\tilde{\epsilon}_t = y_t - \nu h_{t-1} - \gamma y_{t-1} - b_j r_t \sum_{v=1}^{t-t(j-1)-1} d^{v-1}$.

- Für die $\{b_j\}_{j=1}^J$ kann keine bekannte vollständig bedingte Verteilung angegeben werden, so dass der Metropolis-Hastings-Algorithmus zur Anwendung kommt. Die Verteilung von b_j ist proportional zu folgendem Ausdruck:

$$f(b_j|y, \Theta, \{r_t\}_{t=1}^T) \propto \exp\left(-.5 \frac{\sum_{t=t(j-1)+1}^{t(j)} (y_t - \nu h_{t-1} - \gamma y_{t-1} - m_t)^2}{\sigma^2}\right) \frac{1}{\sigma_b} \phi\left(\frac{\ln b_j - \mu_b}{\sigma_b}\right),$$

wobei $m_t = a_j + b_j r_t \sum_{v=1}^{t-t(j-1)-1} d^{v-1}$. Als Vorschlagsdichte im Metropolis-Hastings-Algorithmus wird eine t -Verteilung verwendet, wobei der Lageparameter auf den Wert der korrespondierenden ML-Schätzung und der Skalierungsparameter auf den Wert der geschätzten Varianz des korrespondierenden ML-Schätzers gesetzt wird.

- Die Parameter β_0 und β_1 sind Parameter eines Probit-Modells. Sofern die Werte des latenten Modells $\{r_t^*\}_{t=1}^T$ gegeben sind, sind β_0 und β_1 Parameter eines linearen Modells und es gilt:

$$\beta_0, \beta_1|\{r_t^*\}_{t=1}^T, \{r_t\}_{t=1}^T, \{y_t\}_{t=1}^T \sim N\left((X'_\beta \Omega_\beta^{-1} X_\beta + \Omega_\beta^{p-1})^{-1}(X'_\beta \Omega_\beta^{-1} r^* + \Omega_\beta^{p-1} \mu_\beta^p); (X'_\beta \Omega_\beta^{-1} X_\beta + \Omega_\beta^{p-1})^{-1}\right),$$

wobei X_β aus einer Konstanten sowie dem verzögerten Spannungsindex multipliziert mit den Regimevariablen $\{r_t\}_{t=1}^T$ besteht. Die Latente des Probit-Modells wird mit dem Verfahren von Albert und Chib (1993a) ermittelt.

Um die bedingende Variable $\{r_t\}_{t=1}^T$ herauszuintegrieren, wird der von DeJong et al. (2005) vorgeschlagene Importance-Sampler verwendet. Für eine allgemeine Darstellung zur Technik des Importance-Sampling siehe Richard (1995) oder Stern (1997). Die Marginale Likelihood ergibt sich als

$$f(\{y_t\}_{t=1}^T) = \sum_{\{r_t\}_{t=1}^T} f(\{y_t\}_{t=1}^T, \{r_t\}_{t=1}^T).$$

Alle Varianten der Regimevariable zu berücksichtigen ist zu rechenintensiv. Daher werden die Ergebnisse der konditionalen Schätzung des Modells zur Formulierung eines Importance-Samplers für $\{r_t\}_{t=1}^T$ genutzt. Gegeben die ML-Schätzung der Parameter $\hat{\Theta}$ hat die Wahrscheinlichkeit eines Regimewechsels die folgende Form:

$$\pi_{t+1} = P(r_{t+1} = -r_t | r_t, h_t) = \Phi(\hat{\beta}_0 + \hat{\beta}_1 r_t h_t)$$

und der resultierende Importance-Sampler

$$h(\{r_t\}_{t=1}^T | \{y_t\}_{t=1}^T, \hat{\Theta}) = \pi_t^{\tilde{r}_t} (1 - \pi_t)^{(1 - \tilde{r}_t)}$$

kann von $t = 1$ bis $t = T$ durchlaufen werden, um Züge von $\{r_t\}_{t=1}^T$ zu generieren. Diese Züge werden zur Approximation der Marginalen Likelihood herangezogen, wobei $f^*(\{y_t\}_{t=1}^T)$ für die approximierende MC Marginale Likelihood steht und G die Anzahl der Züge aus dem Importance-Sampler darstellt:

$$f^*(\{y_t\}_{t=1}^T) = \frac{1}{G} \sum_{g=1}^G \frac{f(\{y_t\}_{t=1}^T, \{r_t^{(g)}\}_{t=1}^T)}{h(\{r_t^{(g)}\}_{t=1}^T | \{y_t\}_{t=1}^T, \hat{\Theta})},$$

wobei $f(\{y_t\}_{t=1}^T, \{r_t^{(g)}\}_{t=1}^T)$ entsprechend dem Verfahren von Chib (1995) mit Hilfe des zuvor dargestellten Gibbs-Samplers (mit einem MH-Schritt) errechnet wird. Die Ergebnisse in Tabelle 2.4 basieren auf $G = 1500$.

Tabelle A.1: Priorszenarien

Sz.	σ^{2p}	λ^p	κ^p	Sz.	σ^{2p}	λ^p	κ^p	Sz.	σ^{2p}	λ^p	κ^p
1.	10	1	1	4.	5	1	1	7.	2	1	1
2.	10	1	0,1	5.	5	1	0,1	8.	2	1	0,1
3.	10	0,1	0,1	6.	5	0,1	0,1	9.	2	0,1	0,1

Sensitivitätsanalyse

Für einzelne Parameter der a priori Verteilungen werden jeweils drei verschiedene Werte angenommen und kombiniert, so dass sich neun Szenarien ergeben. Die Tabelle A.1 zeigt die Unterschiede zwischen den Szenarien auf. Hier nicht aufgeführte Hyperparameter nehmen in allen neun Szenarien die gleichen Werte an. Die konkreten Werte finden sich an den Stellen, wo die entsprechenden Hyperparameter eingeführt worden sind. Der Hyperparameter μ^p nimmt jeweils der Wert null an.

A.3 Die Skala von Jeffreys

Das Verhältnis der Werte der Marginalen Likelihood zweier Modelle gibt Aufschluss über die relative Modellgüte. Zur Interpretation dieses Verhältniswertes schlägt Jeffreys (1961) eine Skala vor; die verschiedenen Stufen der möglichen Verhältniswerte entsprechende Evidenzniveaus zuordnet. Die Skala ist im Folgenden für die logarithmierten Verhältniswerte angegeben.

Sei nun $f_A(Y)$ der Wert der Marginalen Likelihood für das Modell A und $f_B(Y)$ der Wert der Marginalen Likelihood für das Modell B . Dann wird das Verhältnis

$$BF = \frac{f_A(Y)}{f_B(Y)}$$

als Bayes-Faktor bezeichnet. In logarithmierter Form ergibt sich:

$$\log BF = \log f_A(Y) - \log f_B(Y).$$

Werte für $\log BF$ größer Null werden als Evidenz für das Modell A aufgefasst. Umgekehrt werden Werte kleiner Null als Evidenz für das Modell B aufgefasst. Dem Betrag der Werte von $\log BF$ lassen sich mit der Skala von Jeffreys verschiedene Stärken der Evidenz zuordnen:

0	<	$\log BF$	≤	1,15	sehr schwache Evidenz,
1,15	<	$\log BF$	≤	2,3	schwache Evidenz,
2,3	<	$\log BF$	≤	4,6	starke bis sehr starke Evidenz,
4,6	<	$\log BF$			entscheidende Evidenz.

A.4 Varianzbruch und Gibbs-Sampler

Die Gibbs-Sampler für die AR-Modelle sowie die MS-Modelle ohne Bruch entsprechen den in Abschnitt A.2 dargestellten. Die in Kapitel 4 verwendeten Prior sind sämtlich in Tabelle A.2 angegeben. Ein Unterschied in den angesprochenen Gibbs-Samplern ergibt sich durch die Berücksichtigung eines unbekanntes Bruchs. Dessen vollständig bedingte Dichte ist proportional zum folgenden Ausdruck:

$$P(t^* = \tilde{t} | G_T, \Theta) \propto (1 - v)v^{\tilde{t}-T_1-1} f(\{y_t\}_{t=1}^T | \Theta, t^* = \tilde{t}), \quad T_1 < \tilde{t} < T_2,$$

wobei $f(\{y_t\}_{t=1}^T | \Theta, t^* = \tilde{t})$ die Likelihood gegeben den Bruchpunkt \tilde{t} angibt und v der Parameter der restringierten Markov-Kette ist, der der Bruch folgt. Die Werte T_1 und T_2 geben die sicheren Randbereiche an, in denen der Bruch noch nicht $1 \rightarrow T_1$ oder bereits $T - 2 \rightarrow T$ stattgefunden hat.

Mit Hilfe dieses Ausdrucks können für alle möglichen Bruchpunkte Werte berechnet werden. Indem durch deren Summe normalisiert wird, erhält man eine Wahrscheinlichkeitsmassenfunktion aus der Züge generiert werden können. Somit wird der Bruchpunkt als zusätzlicher Block in

den Gibbs-Sampler integriert. Das Vorgehen entspricht einem Multi-Move-Sampler für restriktierte Markov-Ketten. Bei den anderen Parametern müssen die zwei Varianzregime entsprechend berücksichtigt werden. Für die vollständig bedingte Verteilung der Mittelwertparameter μ und $\{\phi_\ell\}_{\ell=1}^k$ im AR-Modell mit Bruch in der bedingten Varianz

$$\mu, \{\phi_\ell\}_{\ell=1}^k | y, \tau \sim N \left((X'\Omega^{-1}X + \Omega^{p-1})^{-1}(X'\Omega^{-1}y + \Omega^{p-1}\mu^p); \tau^{-1}(X'\Omega^{-1}X + \Omega^{p-1})^{-1} \right)$$

ist zu beachten, dass die Diagonalmatrix Ω nicht mehr einheitlich mit $1/\tau$ auf der Diagonalen besetzt ist, sondern die ersten \tilde{t} Diagonalelemente gleich $1/\tau_1$ und die folgenden Diagonalelemente gleich $1/\tau_2$ sind. Entsprechend sind zwei Präzisionen zu berücksichtigen, die die folgenden vollständig bedingten Verteilungen haben:

$$\begin{aligned} \tau_1 | \mu, \{\phi_\ell\}_{\ell=1}^k, y, \tilde{t} &\sim \text{Gam} \left(\lambda^p + \sum_{t=1}^{\tilde{t}} \hat{\epsilon}_t^2 / 2, \kappa^p + \tilde{t} / 2 \right), \\ \tau_2 | \mu, \{\phi_\ell\}_{\ell=1}^k, y, \tilde{t} &\sim \text{Gam} \left(\lambda^p + \sum_{t=\tilde{t}+1}^T \hat{\epsilon}_t^2 / 2, \kappa^p + \frac{T - \tilde{t} + 1}{2} \right). \end{aligned}$$

Für die Markov-Switching-Modelle ist die Berücksichtigung eines Varianzbruchs analog zu sehen. Ebenfalls muss die besondere Form der Heteroskedastie in die vollständig bedingten Dichten der Mittelwertparameter einfließen, es werden zwei Präzisionen gezogen und der Bruchpunkt selber bildet einen zusätzlichen Block im Gibbs-Sampler.

Das DLR-Modell, das in der Analyse des Strukturbruchs Anwendung findet, ist im Vergleich zum DLR-Modell in Kapitel 2 in einiger Hinsicht modifiziert. Die Anzahl der Regime ist auf neun festgelegt und die Regimekoeffizienten a_j und b_j werden nicht als zufällig angesehen, sondern als Parameter des Modells. Diese Modifikationen vereinfachen die Analyse. Der Gibbs-Sampler des DLR-Modells mit zufälligen Regimekoeffizienten, der in Abschnitt A.2 erläutert ist, muss entsprechend modifiziert werden. Die Parameter $\mu_{a,1}$, $\mu_{a,2}$, μ_b , σ_a^2 und σ_b^2 sowie die korrespondierenden a priori Verteilungen und Likelihoodbestandteile entfallen. Dafür werden 18 zusätzliche Parameter $\{a_j\}_{j=1}^9$, $\{b_j\}_{j=1}^9$ berücksichtigt. Für a_j wird a priori eine Normalverteilung angenommen und für b_j eine gestutzte Normalverteilung um die Positivität sicherzustellen. Die Hyperparameter sind in Tabelle A.2 angegeben. Als vollständig bedingte Verteilungen von a_j und b_j ergeben sich dann Normal- bzw. gestutzte Normalverteilungen. Der MH-Schritt entfällt. Die vollständig bedingten Dichten von ν , γ , β_0 und β_1 entsprechen den in Abschnitt A.2 dargestellten mit dem Unterschied, dass im Fall des Varianzbruchs die Heteroskedastie in den vollständig bedingten Verteilungen der Mittelwertparameter berücksichtigt werden muss. Dies geschieht analog zur Darstellung für das AR-Modell. Ferner müssen dann ebenfalls zwei Präzisionen gezogen werden, deren Verteilungen im wesentlichen denen im AR-Fall entsprechen,

wobei die zusätzlichen bzw. unterschiedlichen bedingenden Parameter und die Zustandsvariable r_t bei der Berechnung der Residuen $\hat{\epsilon}_t$ berücksichtigt werden.

Ein weiterer Unterschied im modifizierten DLR-Modell ist, dass die Zustandsvariable r_t , die die Mittelwertregime steuert, jetzt in den Gibbs-Sampler integriert wird. Die Zustandsvariable r_t wird implizit durch die Regimewechselpunkte gezogen. Die Regimewechselpunkte werden sequentiell in Anlehnung an das konditionale Verfahren der ML-Schätzung in DeJong et al. (2005) gezogen. Es gibt neun Regime und acht Regimewechselpunkte $j^* = 1, \dots, 8$. Der Zeitpunkt eines Regimewechsels $t(j^*)$ wird bedingt auf die anderen Regimewechselpunkte J^* betrachtet:

$$P(t(j^*) = \tilde{t} | T_{J^*}, \{y_t\}_{t=1}^T, \{d_t\}_{t=1}^T, \Theta) \propto f(\{y_t\}_{t=1}^T, t(j) = \tilde{t} | T_{J^*}, \{d_t\}_{t=1}^T, \Theta), \quad j^* : 1 \rightarrow \bar{8}.$$

Für den Wert \tilde{t} entspricht der Ausdruck der Likelihood des Modells gegeben die Zustandsvariablen $\{r_t\}_{t=1}^T$, die durch T_{J^*} und $t(j) = \tilde{t}$ definiert sind. Θ sei hier ein Platzhalter für sämtliche Modellparameter. Letztlich entspricht $P(t(j^*) = \tilde{t} | T_{J^*}, \{y_t\}_{t=1}^T, \{d_t\}_{t=1}^T, \Theta)$ einer multinomialen Verteilung, die durch die Summe der Wahrscheinlichkeiten normalisiert werden kann und somit einen Ausdruck ergibt, aus dem direkt Züge ermittelt werden können. Das sequentielle Verfahren verfährt dabei so, dass mit dem ersten Wechselpunkt bedingt auf die sieben folgenden begonnen wird. Dann wird bedingt auf den Zug des Ersten und auf die sechs letzten der zweite Wechselpunkt gezogen usw.

Die Gibbs-Sampler werden genutzt um die Bayesianischen Schätzungen durchzuführen und um im Rahmen der von Chib (1995) vorgeschlagenen Methode die a posteriori Verteilungen zu berechnen, die einen Bestandteil der Marginalen Likelihood entsprechend der Gleichung 2.22 darstellen. Die korrespondierenden Likelihoods, die zur Berechnung der Marginalen Likelihoods notwendig sind, hängen im Falle der Modelle mit Bruch von den latenten Variablen d_t ab. Weil d_t einer restringierten Markov-Kette folgt, kann mit Hilfe des Hamilton-Filters über diese Variablen integriert werden. Im Falle des DLR-Modells spielt eine zweite Regimevariable eine Rolle. Um über die dazugehörigen Zustandsvariablen r_t zu integrieren wird wie auch im DLR-Modell in Kapitel 2 ein Importance-Sampling-Ansatz verwendet. An dieser Stelle muss allerdings berücksichtigt werden, dass die Anzahl der Regime mit neun vorgegeben ist. Das an dieser Stelle verwendete Verfahren stellt sich also wie folgt dar:

Als Importance-Sampler wird eine gestutzte multivariate Bernoulli-Verteilung der folgenden Form genutzt:

$$m(\{r_t\}_{t=1}^T) = \left[\prod_{t=1}^T \hat{p}_t^{r_t} (1 - \hat{p}_t)^{1-r_t} \right] \mathcal{I}_{\{\mathcal{S}_{\bar{j}}\}}(\{r_t\}_{t=1}^T) / P(\{r_t\}_{t=1}^T \in \mathcal{S}_{\bar{j}}),$$

wobei \hat{p}_t die mit Hilfe des Gibbs-Samplers geschätzte Wahrscheinlichkeit für $r_t = 1$ darstellt und $\mathcal{I}_{\{\mathcal{S}_{\bar{j}}\}}$ eine Indikatorfunktion ist, die die Anzahl von genau acht Regimewechseln sicherstellt. Entsprechend ist $\mathcal{S}_{\bar{j}}$ die Menge aller Sequenzen von $\{r_t\}_{t=1}^T$, die genau acht Regimewechsel

Tabelle A.2: Priorspezifikationen

Parameter	(I)	(II)	(III)
		AR-Modell	
$(\mu_0, \mu_1)'$	N(0,10)	N(0,10)	N(0,5)
$\{(\phi_{1,i}, \dots, \phi_{4,i})'\}_{i=0,1}$	N(0,10 · I)	N(0,10 · I)	N(0,5 · I)
$1/\sigma_0^2, 1/\sigma_1^2$	Gam(0.02,5)	Gam(0.05,2)	Gam(0.1,1)
v	Beta(8,0.2)	Beta(8,0.1)	Beta(8,0.1)
		MS-Modell	
μ_{10}, μ_{11}	N(2,10) $I_{(0.5,\infty)}(\cdot)$	N(2,10) $I_{(0.5,\infty)}(\cdot)$	N(2,5) $I_{(0.5,\infty)}(\cdot)$
μ_{00}, μ_{01}	N(0,10) $I_{(-\infty,0.5)}(\cdot)$	N(0,10) $I_{(-\infty,0.5)}(\cdot)$	N(0,5) $I_{(-\infty,0.5)}(\cdot)$
$(\phi_1, \dots, \phi_4)'$	N(0,10 · I)	N(0,10 · I)	N(0,5 · I)
p, q	Beta(6,2)	Beta(6,2)	Beta(6,2)
$1/\sigma_0^2, 1/\sigma_1^2$	Gam(0.02,5)	Gam(0.05,2)	Gam(0.1,1)
v	Beta(8,0.2)	Beta(8,0.1)	Beta(8,0.1)
		DLR-Modell	
$(\nu, \gamma)'$	N(0,10 · I)	N(0,10 · I)	N(0,5 · I)
$\{(a_j, b_j)'\}_{j=1}^9$	N(0,10 · I) $I_{(0,\infty)}(b_j)$	N(0,10 · I) $I_{(0,\infty)}(b_j)$	N(0,5 · I) $I_{(0,\infty)}(b_j)$
$(\beta_0, \beta_1)'$	N(0,10 · I)	N(0,10 · I)	N(0,5 · I)
$1/\sigma_0^2, 1/\sigma_1^2$	Gam(0.02,5)	Gam(0.05,2)	Gam(0.01,1)
v	Beta(8,0.2)	Beta(8,0.1)	Beta(8,0.1)

Hinweis: I bezeichnet die Einheitsmatrix und $\mathcal{N}(\cdot, \cdot)_{\mathcal{I}(l,h)}(z)$ repräsentiert eine gestutzte Normalverteilung, wobei der Träger von z auf das Intervall (l, h) beschränkt ist.

erfüllen. Die entsprechende MC-Approximation der unbedingten Likelihood ist dann:

$$f(\{y_t\}_{t=1}^T | \Theta) \doteq \frac{1}{G} \sum_{g=1}^G \frac{f(\{y_t\}_{t=1}^T, (\{\tilde{r}_t\}_{t=1}^T)^{(g)} | \Theta)}{m((\{\tilde{r}_t\}_{t=1}^T)^{(g)})},$$

wobei $(\{\tilde{r}_t\}_{t=1}^T)^{(g)}$ eine Sequenz darstellt, die aus dem Importance-Sampler $m(\cdot)$ gezogen wird. Das Verfahren wird auf das Modell ohne Bruch $\mathcal{M}_{DLR,0}$ und das Modell mit Bruch $\mathcal{M}_{DLR,1}$ angewendet. Θ ist entsprechend zu modifizieren und im Modell mit Bruch wird die bedingte Likelihood mit Hilfe des Hamilton-Filters berechnet.

A.5 Marginale Likelihood für ein Modell mit Bruch in der Kovarianz

Um die Marginale Likelihood in einem Modell mit Bruch in der Kovarianz zu evaluieren ist das direkte Vorgehen mit der Methode von Chib (1995) nicht möglich. Der Gibbs-Sampler kann

nicht angewendet werden, da die vollständig bedingten Dichten zum Teil nicht in geschlossener Form vorliegen. Anstatt den Gibbs-Sampler durch den MH-Algorithmus zu ersetzen und mit der Methode von Chib und Jeliazkov (2001) die a posteriori Verteilung zu berechnen, wird an dieser Stelle ein anderer Weg gewählt, der auf der folgenden Darstellung der Marginalen Likelihood beruht:

$$f(\{x_{it}^*\}_{t=1}^T, \{x_{jt}^*\}_{t=1}^T) = \int f(\{x_{it}^*\}_{t=1}^T, \{x_{jt}^*\}_{t=1}^T | \Theta) \pi(\Theta) d\Theta,$$

wobei $\{x_{it}^*\}_{t=1}^T$ und $\{x_{jt}^*\}_{t=1}^T$ die standardisierten Wachstumsraten der Komponenten und Θ die Parameter des Modells ($\Theta = (\rho_0^{ij}, \rho_1^{ij}, v)$) darstellt. Außerdem steht $\pi(\Theta)$ für die a priori Verteilung der Parameter, für die jeweils die Gleichverteilung im Intervall $\rho \in (-1; 1)$ bzw. $v \in (0; 1)$ angenommen wird. Das oben dargestellte Integral ist nicht analytisch lösbar und wird daher mit einem Importance-Sampling-Ansatz approximiert.

$$f(\{x_{it}^*\}_{t=1}^T, \{x_{jt}^*\}_{t=1}^T) \doteq \frac{1}{K} \sum_{k=1}^K \frac{f(\{x_{it}^*\}_{t=1}^T, \{x_{jt}^*\}_{t=1}^T | \tilde{\Theta}^{(k)}) \pi(\tilde{\Theta}^{(k)})}{m(\tilde{\Theta}^{(k)})},$$

wobei $\{\tilde{\Theta}^{(k)}\}_{k=1}^K$ die K Züge aus dem Importance-Sampler $m(\Theta)$ repräsentiert. Als Importance-Sampler wird eine multivariate gestutzte t -Verteilung mit 5 Freiheitsgraden verwendet. Mittelwert und Varianz-Kovarianzmatrix der Parameter entstammen einer ML-Schätzung des Modells.

A.6 Gibbs-Sampler des Gemeinsamen Markov-Switching-Modells

Die Parameter α , β_0 und β_1 bilden den ersten Block von Mittelwertparametern Θ , wobei β_1 zur Identifikation als $\beta_1 = \beta_0 + \beta^*$ parametrisiert wird. A priori wird β^* als trunziert normalverteilt angenommen, so dass $\beta^* \geq 0$. Die gemeinsame trunzierte Normalverteilung der Parameter α , β_0 und β^* hat die folgenden Hyperparameter $\Theta_y^p = 0$ und für die Varianz-Kovarianzmatrix $\Omega_y^p = 10 \cdot I$. Die Parameter der anderen Mittelwertgleichung werden ebenfalls in einen Block zusammengefasst: $\Theta_i = \{\zeta_0, \zeta_1, \eta_0, \eta_1, \xi_0, \xi_1, \rho\}$. Für diesen Blöcke wird a priori eine Normalverteilung mit Vektor der Erwartungswerte $\Theta_2^p = 0$ und einer diagonalen Varianz-Kovarianzmatrix der Form $\Omega_i^p = 10 \cdot I$ angenommen. Für sämtliche Bleibewahrscheinlichkeiten $p_{00}^u, p_{11}^u, p_{00}^w, p_{11}^w, p_{00}^z$ sowie p_{11}^z wird a priori eine Beta-Verteilung mit den Parameterwerten 6 und 2 angenommen. Für die Varianzen wird a priori eine Invers-Gamma-Verteilung angenommen und somit für die Präzisionen eine Gamma-Verteilung. Die Präzision des Varianzzustands 0 in der Geldpolitikgleichung $\tau_{i,0} (= 1/\sigma_{i,0}^2)$ ist folglich a priori Gamma-verteilt mit den Parametern $\lambda_{i,0}^p$ und $\kappa_{i,0}^p$. Entsprechend sind die a priori Parameter der Verteilung von $\tau_{i,1}$ $\lambda_{i,1}^p$ und $\kappa_{i,1}^p$. Analog gelten für $\tau_{y,0} (= 1/\sigma_{y,0}^2)$ die Parameter $\lambda_{y,0}^p$ und $\kappa_{y,0}^p$ und für $\tau_{y,1}$ die Parameter $\lambda_{y,1}^p$ und $\kappa_{y,1}^p$. Da das Vorgehen sehr sensitiv gegenüber den a priori Annahmen zur Varianz ist, werden die

Werte der Parameter der a priori Verteilungen mit den Ländern basierend auf den Ergebnissen von Maximum-Likelihood-Schätzungen variiert. Sie sind in der nachfolgenden Tabelle A.3 angegeben.

Es ergeben sich die folgenden vollständig bedingten Verteilungen, aus denen im Verlauf des Gibbs-Sampler iterativ gezogen wird.

- $\Theta_y | \{y\}_{t=1}^T, \tau_{y,0}, \tau_{y,1}, \{u_t\}_{t=1}^T, \{w_t\}_{t=1}^T$
 $\sim N \left((X'_y \Omega_y^{-1} X_y + \Omega_y^{p-1})^{-1} (X'_y \Omega_y^{-1} y + \Omega_y^{p-1} \Theta_y^p), (X'_y \Omega_y^{-1} X_y + \Omega_y^{p-1})^{-1} \right) I_{(0,\infty)}(\beta^*),$
wobei die Matrix X_y eine Konstante, die Zinsdifferenz multipliziert mit der Zustandsvariable sowie die Zinsdifferenz multipliziert mit dem Komplement enthält. Ω_y setzt sich aus der Zustandsvariable der Varianz $\{w_t\}_{t=1}^T$ sowie den Präzisionen $\tau_{y,0}$ und $\tau_{y,1}$ zusammen.
- $\Theta_i | \{i\}_{t=1}^T, \tau_{i,0}, \tau_{i,1}, \{u_t\}_{t=1}^T, \{z_t\}_{t=1}^T$
 $\sim N \left((X'_i \Omega_i^{-1} X_i + \Omega_i^{p-1})^{-1} (X'_i \Omega_i^{-1} y + \Omega_i^{p-1} \Theta_i^p), (X'_i \Omega_i^{-1} X_i + \Omega_i^{p-1})^{-1} \right),$
wobei die Matrix X_i eine Konstante, die Inflation und den Output-Gap jeweils multipliziert mit der Zustandsvariable sowie multipliziert mit dem Komplement enthält und ferner den verzögerten Zins enthält. Ω_i setzt sich aus der Zustandsvariable der Varianz $\{z_t\}_{t=1}^T$ sowie den Präzisionen $\tau_{i,0}$ und $\tau_{i,1}$ zusammen.
- $\tau_{y,0} | \Theta_y, \{y_t\}_{t=1}^T, \{X_{y,t}\}_{t=1}^T, \{u_t\}_{t=1}^T, \{w_t\}_{t=1}^T$
 $\sim \text{Gam} \left(\lambda_{y,0}^p + \sum_t 1(w_t = 0) \cdot \tilde{e}_t^2 / 2, \kappa_{y,0}^p + \sum_t 1(w_t = 0) / 2 \right)$
- $\tau_{y,1} | \Theta_y, \{y_t\}_{t=1}^T, \{X_{y,t}\}_{t=1}^T, \{u_t\}_{t=1}^T, \{w_t\}_{t=1}^T$
 $\sim \text{Gam} \left(\lambda_{y,1}^p + \sum_t 1(w_t = 1) \tilde{e}_t^2 / 2, \kappa_{y,1}^p + \sum_t 1(w_t = 1) / 2 \right)$
- $\tau_{i,0} | \Theta_i, \{i_t\}_{t=1}^T, \{X_{i,t}\}_{t=1}^T, \{u_t\}_{t=1}^T, \{z_t\}_{t=1}^T$
 $\sim \text{Gam} \left(\lambda_{i,0}^p + \sum_t 1(z_t = 0) \cdot \tilde{e}_t^2 / 2, \kappa_{i,0}^p + \sum_t 1(z_t = 0) / 2 \right)$
- $\tau_{i,1} | \Theta_i, \{i_t\}_{t=1}^T, \{X_{i,t}\}_{t=1}^T, \{u_t\}_{t=1}^T, \{z_t\}_{t=1}^T$
 $\sim \text{Gam} \left(\lambda_{i,1}^p + \sum_t 1(z_t = 1) \tilde{e}_t^2 / 2, \kappa_{i,1}^p + \sum_t 1(z_t = 1) / 2 \right)$
- $p_{11}^u | \{u_t\}_{t=1}^T \sim \text{Beta}(n_{11}^u + v^p, n_{12}^u + w^p)$
- $p_{22}^u | \{u_t\}_{t=1}^T \sim \text{Beta}(n_{22}^u + v^p, n_{21}^u + w^p),$
- $p_{11}^w | \{w_t\}_{t=1}^T \sim \text{Beta}(n_{11}^w + v^p, n_{12}^w + w^p)$
- $p_{22}^w | \{w_t\}_{t=1}^T \sim \text{Beta}(n_{22}^w + v^p, n_{21}^w + w^p),$
- $p_{11}^z | \{z_t\}_{t=1}^T \sim \text{Beta}(n_{11}^z + v^p, n_{12}^z + w^p)$
- $p_{22}^z | \{z_t\}_{t=1}^T \sim \text{Beta}(n_{22}^z + v^p, n_{21}^z + w^p),$

- $\{u_t\}_{t=1}^T | \Theta_y, \Theta_i, \{i_t\}_{t=1}^T, \{y_t\}_{t=1}^T, \{X_{\{i,y\},t}\}_{t=1}^T, \tau_{i,0}, \tau_{i,1}, \tau_{y,0}, \tau_{y,1}, \{w_t\}_{t=1}^T, \{z_t\}_{t=1}^T, p_{11}^u, p_{22}^u$
 $\sim P(u_T | I_T) \prod_{t=1}^{T-1} P(u_t | u_{t+1}, I_t)$

wobei die Informationsmenge I_t alle Parameter sowie die Variablen bis zum Zeitpunkt t enthält.

- $\{w_t\}_{t=1}^T | \Theta_y, \{y_t\}_{t=1}^T, \{X_{y,t}\}_{t=1}^T, \tau_{y,0}, \tau_{y,1}, \{u_t\}_{t=1}^T, p_{11}^w, p_{22}^w$
 $\sim P(w_T | I_T) \prod_{t=1}^{T-1} P(w_t | w_{t+1}, I_t)$
- $\{z_t\}_{t=1}^T | \Theta_i, \{i_t\}_{t=1}^T, \{X_{i,t}\}_{t=1}^T, \tau_{i,0}, \tau_{i,1}, \{u_t\}_{t=1}^T, p_{11}^z, p_{22}^z$
 $\sim P(z_T | I_T) \prod_{t=1}^{T-1} P(z_t | z_{t+1}, I_t)$

Die Marginale Likelihood wird mit der Methode von Chib (1995) berechnet. Dabei muss ein verkürzter Gibbs-Sampler verwendet werden, wobei in diesem nur noch die Zustandsvariablen und die Varianzparameter gezogen werden und für die Mittelwertparameter sowie die Parameter der Markov-Ketten die Bayes-Schätzer aus dem vollständigen Gibbs-Sampler eingesetzt werden.

Tabelle A.3: Prior der Präzisionen

	Deutschland		USA	
	homosked.	heteros.	homosked.	heteros.
$\lambda_{i,0}^p$	7	7	30	30
$\kappa_{i,0}^p$	2	2	1	1
$\lambda_{i,1}^p$	–	–	4	4
$\kappa_{i,1}^p$	–	–	0,5	0,5
$\lambda_{y,0}^p$	2	5	2	2
$\kappa_{y,0}^p$	0,2	0,02	0,1	0,1
$\lambda_{y,1}^p$	–	7	–	9
$\kappa_{y,1}^p$	–	0,1	–	0,25

Im homoskedastischen Fall sind die Präzisionen $\tau_{y,0}$ und $\tau_{y,1}$ identisch und es wird nur eine Priorverteilung angenommen. Die Prior gelten für das gemeinsame Markov-Switching-Modell wie für das Modell mit zwei getrennten Markov-Switching-Prozessen.

A.7 Dynamisches Faktormodell

Für die Vorhersagemodelle V und VI , die auf die Revisionen des BIP-Wachstums der USA angewandt werden, werden als Regressoren Faktoren verwendet die aus der Vielzahl zur Verfügung stehenden Variablen konstruiert werden.⁶ Grundlegend zur Gewinnung der Faktoren ist das

⁶Vgl. Anhang A.8.

Dynamische Faktormodell:

$$\begin{aligned} Z_t &= \Lambda F_t + \zeta_t, \\ F_t &= \sum_{i=1}^k A_i F_{t-i} + B u_t, \\ u_t &\sim N(0, I_r), \\ \zeta_t &\sim N(0, \Sigma_\zeta), \end{aligned}$$

wobei Z_t den Vektor der verfügbaren makroökonomischen Variablen bezeichnet und F_t die dahinter liegenden Faktoren, die sich entsprechend eines (vektor-)autoregressiven Prozesses ergeben. ζ_t bezeichnet den Vektor der idiosynkratischen Komponenten der Variablen.

Man kann dieses Modell als Zustandsraummodell formulieren und über den Kalman-Filter mit der Maximum-Likelihood-Methode schätzen, wobei die Likelihood numerisch optimiert wird. Unter Berücksichtigung aller Variablen ist es jedoch relativ hoch parametrisiert, so dass die Schätzung sehr viel Rechenzeit beanspruchen kann, insbesondere im Hinblick auf die Out-of-Sample-Analyse, die eine wiederholte Schätzung des Modells verlangt. Giannone et al. (2005) schlagen ein alternatives Verfahren vor, dessen Parameterschätzung auf dem approximativen Faktormodell-Ansatz beruht, aber explizit den dynamischen Charakter der Faktoren berücksichtigt. Faktoren F_t und Faktorladungen Λ werden mit Hilfe der Hauptkomponentenanalyse bestimmt. Wegen der gemischt frequenten Daten wird die Hauptkomponentenanalyse basierend auf dem Interpolationsverfahren mit Hilfe des EM-Algorithmus durchgeführt, vgl. Stock und Watson (2002b). Für die gewonnenen Faktoren wird ein VAR-Modell angepasst und die Parameter A und die Kovarianzmatrix B zweistufig ermittelt.

Gegeben die Schätzungen für $\{\Lambda, A, B, \Sigma_\zeta\}$ werden die Faktoren F mit Kalman-Filter und -Glätter erneut geschätzt. Durch dieses Verfahren wird die Dynamik der Faktoren berücksichtigt und der besonderen Situation am aktuellen Rand kann besser Rechnung getragen werden als durch ein einfaches approximatives Faktormodell.

Unter der Annahme, dass sich die verfügbaren Variablen von der Anzahl N in monatliche Variablen der Anzahl N^m und quartalsweise erhobene Variablen der Anzahl N^q , bei denen es sich um Wachstumsraten handelt, aufteilen, ergeben sich das resultierende Zustandsraummodell, Kalman-Filter und -Glätter wie folgt:

Es seien die folgenden zwei 1×5 Vektoren:

$$C = [1 \ 0 \ 0 \ 0 \ 0] \quad \text{und} \quad D = \begin{bmatrix} \frac{1}{3} & \frac{2}{3} & 1 & \frac{2}{3} & \frac{1}{3} \end{bmatrix}.$$

Ferner sei an dieser Stelle t_m ein monatlicher Zeitindex, der sich wie folgt zum quartalsweisen Index t verhält:

$$\begin{aligned}
t = 1 \text{ (1. Monat im Quartal 1)} &\Leftrightarrow t_m = 1 \\
t = 1 \text{ (2. Monat im Quartal 1)} &\Leftrightarrow t_m = 2 \\
t = v \text{ (1. Monat im Quartal } v) &\Leftrightarrow t_m = 3 \cdot v - 2 \\
t = v \text{ (3. Monat im Quartal } v) &\Leftrightarrow t_m = 3 \cdot v
\end{aligned}$$

Die Quartalswachstumsraten $z_{i,t}^q$ werden in eine monatliche Variable z_{i,t_m}^* abgebildet und die Matrix D^* ergibt sich wie folgt:

$$z_{i,t_m}^* = \begin{cases} z_{i,t}^q & \text{if } t/3 \in \mathbb{N} \\ 0 & \text{otherwise,} \end{cases} \quad D^* = \begin{cases} D & \text{if } t/3 \in \mathbb{N} \\ 0 & \text{otherwise.} \end{cases}$$

Das Zustandsraummodell für den Fall, dass $p \leq 4$:

$$\underbrace{\begin{pmatrix} z_{1,t_m}^m \\ \dots \\ z_{N^m,t_m}^m \\ z_{1,t_m}^* \\ \dots \\ z_{N^q,t_m}^* \end{pmatrix}}_{z_{t_m}} = \underbrace{\begin{pmatrix} \lambda_1 \otimes C \\ \dots \\ \lambda_{N^m,t} \otimes C \\ \lambda_{1^q} \otimes D^* \\ \dots \\ \lambda_{N^q} \otimes D^* \end{pmatrix}}_{\Lambda^*} \underbrace{\begin{pmatrix} F_{t_m} \\ F_{t_m-1} \\ F_{t_m-2} \\ F_{t_m-3} \\ F_{t_m-4} \end{pmatrix}}_{F^*} + \begin{pmatrix} \zeta_{1,t}^m \\ \dots \\ \zeta_{N^m,t}^m \\ \zeta_{1,t}^q \\ \dots \\ \zeta_{N^q,t}^q \end{pmatrix}$$

$$\begin{pmatrix} F_{t_m} \\ F_{t_m-1} \\ F_{t_m-2} \\ F_{t_m-3} \\ F_{t_m-4} \end{pmatrix} = \begin{pmatrix} \mu \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix} + \underbrace{\begin{pmatrix} A_1 & A_2 & \dots & A_4 & 0 \\ I & 0 & 0 & 0 & 0 \\ 0 & I & 0 & 0 & 0 \\ 0 & 0 & I & 0 & 0 \\ 0 & 0 & 0 & I & 0 \end{pmatrix}}_{A^*} \begin{pmatrix} F_{t_m-1} \\ F_{t_m-2} \\ F_{t_m-3} \\ F_{t_m-4} \\ F_{t_m-5} \end{pmatrix} + \begin{pmatrix} Bu_t \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$$

Die latente Variable des Zustandsraummodells wird mit dem Kalman-Filter geschätzt, wobei $F_{q|r}^*$ den Erwartungswert der Zustandsvariablen zum Zeitpunkt q bedingt auf die Informationen zum Zeitpunkt r angibt und $P_{q|r}$ die korrespondierende bedingte Varianz.

$$\begin{aligned}
F_{t_m|t_m-1}^* &= \mu + A^* F_{t_m-1|t_m-1}^* \\
P_{t_m|t_m-1} &= A^* P_{t_m-1|t_m-1} A^{*'} + B^* B^{*'} \\
&\Downarrow \\
z_{t_m|t_m-1} &= \Lambda^* F_{t_m|t_m-1}^* \\
\Sigma_{t_m|t_m-1} &= \Lambda^* P_{t_m|t_m-1} \Lambda^{*'} + \Sigma_\zeta \\
&\Downarrow
\end{aligned}$$

$$F_{t_m|t_m}^* = F_{t_m|t_{m-1}}^* + P_{t_m|t_{m-1}} F_{t_m|t_{m-1}}^{*'} \Sigma_{t_m|t_{m-1}}^{-1} (y_{t_m} - y_{t_m|t_{m-1}})$$

$$P_{t_m|t_m} = P_{t_m|t_{m-1}} - P_{t_m|t_{m-1}} \Lambda^{*'} \Sigma_{t_m|t_{m-1}}^{-1} \Lambda^* P_{t_m|t_{m-1}}$$

Mit dem Kalman-Glätter wird dann bedingt auf die Informationen am aktuellen Rand für die anderen Werte der latenten Variable zurückgerechnet :

$$F_{t_m|T_m}^* = F_{t_m|t_m}^* + P_{t_m|t_m} A^{*'} P_{t_{m+1}|t_m}^{-1} (F_{t_{m+1}|T_m}^* - \mu - A^* F_{t_m|t_m}^*)$$

$$P_{t_m|T_m} = P_{t_m|t_m} + P_{t_m|t_m} A^{*'} P_{t_{m+1}|t_m}^{-1} (P_{t_{m+1}|T_m} - P_{t_{m+1}|t_m}) P_{t_{m+1}|t}^{-1} A^* P_{t_m|t_m}$$

Es werden bis zu fünf Faktoren unterstellt und jeweils durchgespielt. Verfahren zur Bestimmung der Anzahl der Faktoren, wie das von Bai und Ng (2002) bieten sich bei gemischt frequenten Daten nicht an. Die Lag-Länge des VAR-Modells wurde mit Hilfe des BIC bestimmt. Nur die Faktorkonstellation mit den besten Vorhersageeigenschaften wird berichtet. Es handelt sich in allen Fällen um ein Ein-Faktor-Modell mit einer bzw. zwei Verzögerten im autoregressiven Prozess. Dieses Ein-Faktor-Modell zeigt sich auch gegenüber einem exakten dynamischen Faktormodell mit zwei Faktoren und einer kleinen Auswahl an Variablen, darunter auch das BIP-Wachstum selbst (zur Schätzung wurde das in Mariano und Murasawa (2003) besprochene Verfahren verwendet), überlegen.

A.8 Echtzeitdaten – USA

Quartalsdaten

real output (GNP and GDP)
output-price index
real personal consumption - services
real personal consumption - durables
real personal consumption - nondurables
real investment business
real investment residential
real investment change in inventories
real exports
real imports
price index for imports
nominal corporate profits after tax

Quelle: Philadelphia FED

Monatsdaten - monatliche Veröffentlichung

index of industrial production, total
index of industrial production, manufacturing
employees on non-farm payrolls
capacity utilization, total
capacity utilization, manufacturing
new privately owned housings units started
weekly hours worked, total
weekly hours worked, goods-producing sector
weekly hours worked, service-producing sector

Quelle: Philadelphia FED

Monatsdaten - quartalsweise Veröffentlichung

monetary base
M1
M2
unemployment rate

Quelle: Philadelphia FED

Nicht revidierte Monatsdaten

oil price
stock prices (Dow Jones)
new orders
consumer sentiment
business climate
exchange rate Dollar/DM
terms of trade
yield spread (10 years/ 3 months)
yield spread (6 months/ 3 months)
yield spread (1 month/ 3 months)
yield spread (prime rate/ 3 months)
yield spread (AAA/ 3 months)
yield spread (BAA/ 3 months)
yield spread (6 months CD/ 3 months)
yield spread (1 month CD/ 3 months)

Quellen: OECD-Datenbank und FRED

Literaturverzeichnis

- [1] Adelman, I. and F. Adelman: 1959, ‘The dynamic properties of the KleinGoldberger model’. *Econometrica* **4**, 596–625.
- [2] Albert, J. and S. Chib: 1993a, ‘Bayesian analysis binary and polychotomous response data’. *Journal of the American Statistical Association* **88**, 669–679.
- [3] Albert, J. and S. Chib: 1993b, ‘Bayesian analysis via Gibbs sampling of autoregressive time series subject to Markov mean and variance shifts’. *Journal of Business and Economic Statistics* **11**, 1–15.
- [4] Altissimo, F., R. Cristadoro, M. Forni, M. Lippi, and G. Veronese: 2006, ‘New eurocoin: Tracking economic growth in real time’. Discussion Paper 5633, CEPR.
- [5] Amengual, D. and M. W. Watson: 2007, ‘Consistent Estimation of the Number of Dynamic Factors in a Large N and T Panel’. *Journal of Business and Economic Statistics* **25**(1), 91–96.
- [6] Andrews, D.: 1993, ‘Tests for Parameter Instability and Structural Change with Unknown Change Point’. *Econometrica* **61**, 821–856.
- [7] Andrews, D. and W. Ploberger: 1994, ‘Optimal Tests when a Nuisance Parameter is Present Only Under the Alternative’. *Econometrica* **62**, 1383–1414.
- [8] Ang, A., M. Piazzesi, and M. Wei: 2006, ‘What does the Yield curve tell us about GDP growth?’. *Journal of Econometrics* **131**, 359–403.
- [9] Angelini, E., J. Henry, and M. Marcellino: 2003, ‘Interpolation and backdating with a large information set’. Working Paper 252, European Central Bank.
- [10] Ashley, R. A. and D. M. Patterson: 2006, ‘Evaluating the effectiveness of state-switching time series models for US real output’. *Journal of Business and Economic Statistics* **24**(3), 266–277.

- [11] Aßmann, C., J. Högrefe, and R. Liesenfeld: 2006, ‘The Decline in German Output Volatility: A Bayesian Analysis’. Economic Working Paper 2006-02, University of Kiel.
- [12] Assenmacher, W.: 1998, *Konjunkturtheorie*. München, Wien: Oldenbourg, 8 edition.
- [13] Assenmacher-Wesche, K.: 2006, ‘Estimating Central Banks preferences from a time-varying empirical reaction function’. *European Economic Review* **50**, 1951–1974.
- [14] Bai, J.: 2003, ‘Inferential theory for factor models of large dimensions’. *Econometrica* **71**(1), 135–171.
- [15] Bai, J. and S. Ng: 2002, ‘Determining the number of factors in approximate factor models’. *Econometrica* **70**(1), 191–221.
- [16] Bai, J. and S. Ng: 2005, ‘Tests for Skewness, Kurtosis, and Normality for Time Series Data’. *Journal of Business and Economic Statistics* **23**(1), 49–60.
- [17] Bai, J. and S. Ng: 2007, ‘Determining the Number of Primitive Shocks in Factor Models’. *Journal of Business and Economic Statistics* **25**(1), 52–60.
- [18] Bandholz, H. and M. Funke: 2003, ‘In Search of Leading Indicators of Economic Activity in Germany’. *Journal of Forecasting* **22**, 277–297.
- [19] Baxter, M. and R. G. King: 1999, ‘Measuring Business Cycles: Approximate Band-Pass Filters for Economic Time Series’. *The Review of Economics and Statistics* **81**(4), 575–593.
- [20] Beaudry, P. and G. Koop: 1993, ‘Do recessions permanently change output?’. *Journal of Monetary Economics* **31**, 149–163.
- [21] Belaire-Franch, J. and D. Contrera: 2003, ‘An Assessment of International Business Cycle Asymmetries using Clements and Krolzigs Parametric Approach’. *Studies in Nonlinear Dynamics and Econometrics* **6**(4). Replication 1.
- [22] Benner, J. and C.-P. Meier: 2004, ‘Prognosegüte alternativer Frühindikatoren für die Konjunktur in Deutschland’. *Jahrbücher für Statistik und Nationalökonomie* **224**(6), 639–652.
- [23] Bernanke, B. and J. Boivin: 2003, ‘Monetary Policy in a Data-Rich Environment’. *Journal of Monetary Economics* **50**(3), 525–546.
- [24] Bernard, H. and S. Gerlach: 1998, ‘Does the Term Structure Predict Recessions? The International Evidence’. *International Journal of Finance and Economics* **3**, 195–215.
- [25] Birchenhall, C. R., H. Jessen, D. R. Osborn, and P. Simpson: 1999, ‘Predicting US business-cycle regimes’. *Journal of Business and Economic Statistics* **17**(3), 313–323.

- [26] Birchenhall, C. R., D. R. Osborn, and M. Sensier: 2001, ‘Predicting UK business cycle regimes’. *Scottish Journal of Political Economy* **48**(2), 179–195.
- [27] Boldin, M. D.: 1994, ‘Dating Turning Points in the Business Cycle’. *The Journal of Business* **67**(1), 97–131.
- [28] Bradley, M. D. and D. W. Jansen: 1997, ‘Nonlinear Business Cycle Dynamics: Cross-Country Evidence of the Persistence of Aggregate Shocks’. *Economic Inquiry* **35**(3), 495–509.
- [29] Brain, C. W. and S. S. Shapiro: 1983, ‘A Regression Test for Exponentiality: Censored and Complete Samples’. *Technometrics* **25**(1), 69–76.
- [30] Breitung, J. and D. Jagodzinski: 2002, ‘Prognoseeigenschaften alternativer Indikatoren für die Konjunkturentwicklung in Deutschland’. Discussion Paper 36, Sonderforschungsbereich 373.
- [31] Breitung, J. and C. Schumacher: 2006, ‘Real-time forecasting of GDP based on a large factor model with monthly and quarterly data’. Deutsche Bundesbank, Discussion Paper, 34.
- [32] Brock, W., W. Dechert, J. Scheinkman, and B. LeBaron: 1996, ‘A Test for Independence Based on the Correlation Dimension’. *Econometric Reviews* **15**, 197–235.
- [33] Bry, G. and C. Boschan: 1971, ‘Cyclical analysis of time series: selected procedures and computer programs’. Technical Paper 20, NBER. Columbia University Press.
- [34] Buch, C. M., J. Doepke, and C. Pierdzioch: 2004, ‘Business Cycle Volatility in Germany’. *German Economic Review* **5**, 451–479.
- [35] Bueno, R.: 2004, ‘Taylor Rule with Hidden States’. Working paper, University of Chicago.
- [36] Burns, A. F. and W. C. Mitchell: 1946, *Measuring business cycles*, Vol. NBER Studies in Business Cycles of 2.
- [37] Camacho, M.: 2004, ‘Vector smooth transition regression models for US GDP and the composite index of leading indicators’. *Journal of Forecasting* **23**(3), 173–196.
- [38] Campbell, J. Y. and N. G. Mankiw: 1987, ‘Permanent and Transitory Components in Macroeconomic Fluctuations’. *American Economic Review* **77**(2), 111–117.
- [39] Cancelo, J. R. and E. Mourelle: 2005, ‘Modeling Cyclical Asymmetries in GDP: International Evidence’. *Atlantic Economic Journal* **33**, 297–309.

- [40] Canova, F.: 1998, ‘Detrending and business cycle facts’. *Journal of Monetary Economics* **41**, 475–512.
- [41] Carrasco, M., L. Hu, and W. Ploberger: 2005, ‘Optimal Test for Markov Switching’. Research paper, University of Rochester.
- [42] Carstensen, K.: 2006, ‘Estimating the ECB policy reaction function’. *German Economic Review* **7**(1), 1–34.
- [43] Carstensen, K. and D. de Antonio Liedo: 2005, ‘A Model for Real-time Data Assessment and Forecasting’. Manuscript.
- [44] Carter, C. and R. Kohn: 1994, ‘On Gibbs sampling for state space models’. *Biometrika* **81**(3), 541–553.
- [45] Chamberlain, G. and M. Rothschild: 1983, ‘Arbitrage, factor structure, and mean-variance analysis on large asset markets’. *Econometrica* **51**(5), 1281–1304.
- [46] Chauvet, M.: 1998, ‘An econometric characterization of business cycle dynamics with factor structure and regime switching’. *International Economic Review* **39**(4), 969–996.
- [47] Chauvet, M. and S. Potter: 2002, ‘Predicting a recession: evidence from the yield curve in the presence of structural breaks’. *Economics Letters* **77**, 245–253.
- [48] Chen, C. W. S. and J. C. Lee: 1995, ‘Bayesian Inference of Threshold Autoregressive Models’. *Journal of Time Series Analysis* **16**(5), 483–492.
- [49] Chib, S.: 1995, ‘Marginal Likelihood from the Gibbs Output’. *Journal of the American Statistical Association* **90**(432), 1313–1321.
- [50] Chib, S.: 2001, *Handbook of Econometrics*, Vol. 5, Chapt. Markov chain Monte Carlo methods: computation and inference, pp. 3569–3649. Amsterdam [u.a.]: Elsevier.
- [51] Chib, S. and E. Greenberg: 1995, ‘Understanding the MetropolisHastings Algorithm’. *American Statistician* **49**, 327–335.
- [52] Chib, S. and I. Jeliazkov: 2001, ‘Marginal Likelihood From the MetropolisHastings Output’. *Journal of the American Statistical Association* **96**(453), 270–281.
- [53] Chow, G. C. and A. Lin: 1971, ‘Best linear unbiased interpolation, distribution, and extrapolation of time series by related series’. *The Review of Economics and Statistics* **53**(4), 372–375.
- [54] Christoffersen, P. F.: 1998, ‘Evaluating Interval Forecasts’. *International Economic Review* **39**(4), 841–862.

- [55] Clarida, R., J. Gali, and M. Gertler: 2000, 'Monetary policy rules and macroeconomic stability: evidence and some theory'. *Quarterly Journal of Economics* **115**(1), 147–180.
- [56] Clark, T. and M. McCracken: 2001, 'Tests of equal forecast accuracy and encompassing for nested models'. *Journal of Econometrics* **105**, 85–110.
- [57] Clark, T. E. and K. D. West: 2007, 'Approximately normal tests of equal predictive accuracy in nested models'. *Journal of Econometrics* **138**, 291–311.
- [58] Clements, M. P. and H.-M. Krolzig: 1998, 'A comparison of the forecast performance of Markov-switching and threshold autoregressive models of US GNP'. *Econometric Journal* **1**, C47–C75.
- [59] Clements, M. P. and H.-M. Krolzig: 2003, 'Business Cycle Asymmetries: Characterization and Testing Based on Markov-Switching Autoregressions'. *Journal of Business and Economic Statistics* **21**(1), 196–211.
- [60] Clements, M. P. and J. Smith: 1997, 'The performance of alternative forecasting methods for SETAR models'. *International Journal of Forecasting* **13**, 463–475.
- [61] Clements, M. P. and J. Smith: 1999, 'A Monte Carlo Study of the Forecasting Performance of empirical SETAR Models'. *Journal of Applied Econometrics* **14**, 123–141.
- [62] Cogley, T. and T. J. Sargent: 2005, 'Drift and Volatilities: Monetary Policies and Outcomes in the Post WWII U.S'. *Review of Economic Dynamics* **8**(2), 262–302.
- [63] Croushore, D.: 2006, 'An Evaluation of Inflation Forecasts from Surveys Using Real-Time Data'. Working Paper 06-19, Federal Reserve Bank of Philadelphia.
- [64] Croushore, D. and T. Stark: 2003, 'A real-time data set for macroeconomists: Does the data vintage matter?'. *The Review of Economics and Statistics* **85**(3), 605–617.
- [65] Davies, R.: 1977, 'Hypothesis testing when a nuisance parameter is present only under the alternative'. *Biometrika* **64**(2), 247–254.
- [66] Davies, R.: 1987, 'Hypothesis testing when a nuisance parameter is present only under the alternative'. *Biometrika* **74**(1), 33–43.
- [67] DeJong, D., R. Liesenfeld, and J.-F. Richard: 2005, 'A Non-Linear Forecasting Model of GDP Growth'. *The Review of Economics and Statistics* **87**, 697–708.
- [68] Dempster, A., N. Laird, and D. Rubin: 1977, 'Maximum likelihood from incomplete data via the EM algorithm'. *Journal of the Royal Statistical Society, Series B* **39**(1), 1–38.

- [69] Diebold, F. and R. Mariano: 1995, ‘Comparing predictive accuracy’. *Journal of Business and Economic Statistics* **13**, 253–263.
- [70] Diebold, F. X., T. A. Gunther, and A. S. Tay: 1998, ‘Evaluating density forecasts with applications to financial risk management’. *International Economic Review* **39**, 863–883.
- [71] Diebold, F. X. and J. A. Lopez: 1996, *Handbook of Statistics*, Vol. 14, Chapt. Forecast Evaluation and Combination, pp. 241–268.
- [72] Diebold, F. X. and G. D. Rudebusch: 1990, ‘A Nonparametric Investigation of Duration Dependence in the American Business Cycle’. *Journal of Political Economy* **98**(3), 596–616.
- [73] Dotsey, M.: 1998, ‘The predictive content of the interest rate term spread for future economic growth’. *Economic quarterly* **84**(3), 31–51.
- [74] Duarte, A., I. A. Venetis, and I. Paya: 2005, ‘Predicting real growth and the probability of recession in the Euro area using the yield spread’. *International Journal of Forecasting* **21**, 261–277.
- [75] Dueker, M. J.: 1997, ‘Strengthening the case for the yield curve as a predictor of U.S. recessions’. *Federal Reserve Bank of St. Louis Review* **79**, 41–51.
- [76] Dueker, M. J.: 2005, ‘Dynamic Forecasts of Qualitative Variables: A Qual VAR Model of U.S. Recessions’. *Journal of Business and Economic Statistics* **23**(1), 96–104.
- [77] Durland, J. M. and T. H. McCurdy: 1994, ‘Duration dependent transitions in a Markov model of US GNP growth’. *Journal of Business and Economic Statistics* **12**(3), 279–288.
- [78] Engel, J., D. Haugh, and A. Pagan: 2005, ‘Some methods for assessing the need for non-linear models in business cycle analysis’. *International Journal of Forecasting* **21**, 651–662.
- [79] Estrella, A.: 2005, ‘Why does the yield curve predict output and inflation?’. *The Economic Journal* **115**, 722–744.
- [80] Estrella, A. and G. Hardouvelis: 1991, ‘The term structure as a predictor of real economic activity’. *Journal of Finance* **46**, 555–576.
- [81] Estrella, A. and F. S. Mishkin: 1997, ‘The predictive power of the term structure of interest rates in Europe and the United States: Implications for the European Central Bank’. *European Economic Review* **41**, 1375–1401.
- [82] Estrella, A., A. P. Rodrigues, and S. Schich: 2003, ‘How stable is the predictive power of the yield curve? Evidence from Germany and the United States’. *The Review of Economics and Statistics* **85**, 45–61.

- [83] Estrella, A. and M. R. Trubin: 2006, 'The Yield Curve as a Leading Indicator: Some Practical Issues'. *Current Issues in Economics and Finance (Federal Reserve Bank of New York)* **12**(5).
- [84] Evans, M.: 2005, 'Where are we now? Real-time estimates of the macro economy'. Working Paper 11064, NBER.
- [85] Everts, M. P.: 2006, 'Duration of Business Cycles'. Mpra paper no. 1219, University of Bern.
- [86] Faust, J., J. Rogers, and J. Wright: 2005, 'News and Noise in G-7 GDP Announcements'. *Journal of Money, Credit, and Banking* **37**(3), 403–419.
- [87] Filardo, A. J.: 1994, 'Business cycle phases and their transitional dynamics'. *Journal of Business and Economic Statistics* **12**(3), 299–308.
- [88] Fixler, D. and B. Grimm: 2006, 'GDP estimates: Rationality tests and turning point performance'. *Journal of Productivity Analysis* **25**, 213–229.
- [89] Forni, M., M. Hallin, F. Lippi, and L. Reichlin: 2001, 'Coincident and leading indicators for the Euro area'. *The Economic Journal* **111**, 62–85.
- [90] Friedman, M.: 1962, 'The Interpolation of Time Series by Related Series'. *Journal of the American Statistical Association* **57**, 729–757.
- [91] Fritsche, U. and V. Kuzin: 2005a, 'Declining output volatility in Germany : impulses, propagation, and the role of monetary policy'. *Applied Economics* **37**(21), 2445–2457.
- [92] Fritsche, U. and V. Kuzin: 2005b, 'Prediction of business cycle turning points in Germany'. *Jahrbücher für Statistik und Nationalökonomie* **225**(1), 22–43.
- [93] Fritsche, U. and S. Stephan: 2002, 'Leading Indicators of German Business Cycle'. *Jahrbücher für Statistik und Nationalökonomie* **222**(3), 290–315.
- [94] Fuhrer, J. C. and S. Schuh: 1998, 'Beyond Shocks: What Causes Business Cycles? An Overview'. *New England Economic Review* pp. 3–24.
- [95] Galbraith, J. W. and G. Tkacz: 2000, 'Testing for asymmetry in the link between the yield spread and output in the G-7 countries'. *Journal of International Money and Finance* **19**, 219–239.
- [96] Gali, J. and L. Gambetti: 2007, 'On the Sources of the Great Moderation'. Working Paper.
- [97] Garcia, R.: 1998, 'Asymptotic null distribution of the likelihood ratio test in Markov switching models'. *International economic review* **39**(3), 763–788.

- [98] Gerberding, C., F. Seitz, and A. Worms: 2005, ‘How the Bundesbank really conducted monetary policy’. *The North American journal of economics and finance* **16**, 277–292.
- [99] Geweke, J.: 1977, ‘The dynamic factor analysis of economic time series’. In: D. Aigner and A. Goldberger (eds.): *Latent Variables in Socio-Economic Models*. Amsterdam: North-Holland, Chapt. 19.
- [100] Geweke, J. F. and K. J. Singleton: 1981, ‘Maximum likelihood confirmatory factor analysis of economic time series’. *International Economic Review* **22**(1), 37–54.
- [101] Ghysels, E., P. Santa-Clara, and R. Valkanov: 2004, ‘The MIDAS touch: Mixed data sampling regression models’. Scientific Series 20, CIRANO.
- [102] Giacomini, R. and B. Rossi: 2006, ‘How Stable is the Forecasting Performance of the Yield Curve for Output Growth?’. *Oxford Bulletin of Economics and Statistics* **68**(Supplement), 783–795.
- [103] Giannone, D., L. Reichlin, and D. Small: 2005, ‘Nowcasting GDP and inflation: Real-time informational content of macroeconomic data releases’. Working Paper 42, Federal Reserve Board, Washington, D.C.
- [104] Golinelli, R. and G. Parigi: 2005, ‘Short-run Italian GDP forecasting and real-time data’. Discussion Paper Series 5302, Centre for Economic Policy Research.
- [105] Goodfriend, M.: 1991, ‘Interest Rates and the Conduct of Monetary Policy’. *Carnegie-Rochester Conference Series on Public Policy* **34**, 7–30.
- [106] Goodwin, T. H.: 1993, ‘Business-Cycle Analysis with a Markov-Switching Model’. *Journal of Business and Economic Statistics* **11**, 331–339.
- [107] Granger, C. W. J., T. Terasvirta, and H. M. Anderson: 1993, *Business cycles, indicators, and forecasting*, Chapt. Modeling nonlinearity over the business cycle, pp. 311–325. Chicago u.a.: Univ. of Chicago Press.
- [108] Hamilton, J. D.: 1989, ‘A new approach to the economic analysis of nonstationary time series and the business cycle’. *Econometrica* **57**, 385–423.
- [109] Hamilton, J. D.: 1990, ‘Analysis of Time Series Subject to Changes in Regime’. *Journal of Econometrics* **45**, 39–70.
- [110] Hamilton, J. D.: 2005, ‘What’s real about the business cycle?’. NBER, Working Paper 11161.
- [111] Hamilton, J. D. and D. H. Kim: 2002, ‘A Reexamination of the Predictability of Economic Activity using the Yield Spread’. *Journal of Money, Credit and Banking* **34**, 340–360.

- [112] Hamilton, J. D. and G. Perez-Quiros: 1996, ‘What do the leading indicators lead?’. *The Journal of Business* **69**(1), 27–49.
- [113] Hansen, B. E.: 1992, ‘The likelihood ratio test under non-standard conditions: Testing the Markov Switching model of GNP’. *Journal of Applied Econometrics* **7**, 61–82.
- [114] Hansen, B. E.: 1996, ‘Inference when a nuisance parameter is not identified under the null hypothesis’. *Econometrica* **64**(2), 413–430.
- [115] Harding, D. and A. Pagan: 2002, ‘Dissecting the cycle: A methodological investigation’. *Journal of Monetary Economics* **49**(2), 365–381.
- [116] Hartley, H.: 1958, ‘Maximum likelihood estimation from incomplete data’. *Biometrics* **14**, 174–194.
- [117] Harvey, C. R.: 1988, ‘The Real Term Structure and Consumption Growth’. *Journal of Financial Economics* **22**, 305–333.
- [118] Harvey, D., S. Leybourne, and P. Newbold: 1997, ‘Testing the equality of prediction mean squared errors’. *International Journal of Forecasting* (13), 281–91.
- [119] Harvey, D., S. Leybourne, and P. Newbold: 1998, ‘Tests for Forecast Encompassing’. *Journal of Business and Economic Statistics* **16**, 254–259.
- [120] Hastings, W. K.: 1970, ‘Monte Carlo Sampling Methods using Markov Chains and their Applications’. *Biometrika* **57**, 97–109.
- [121] Haubrich, J. and A. M. Dombrosky: 1996, ‘Predicting Real Growth Using the Yield Curve’. *Federal Reserve Bank of Cleveland Economic Review* **32**(1), 26–35.
- [122] Hess, G. D. and S. Iwata: 1997, ‘Measuring and Comparing Business-Cycle Features’. *Journal of Business and Economic Statistics* **15**(4), 432–444.
- [123] Heubes, J.: 1991, *Konjunktur und Wachstum*. München: Vahlen.
- [124] Hicks, J. R.: 1939, *Value and Capital*. Oxford: Oxford University Press.
- [125] Hodrick, R. and E. Prescott: 1997, ‘Post-War US Business Cycles: An Empirical Investigation’. *Journal of Money, Credit and Banking* **29**, 1–16.
- [126] Hogrefe, J.: 2007, ‘The yield spread and GDP growth - Time Varying Leading Properties and the Role of Monetary Policy’. Economic Working Papers 2007-12, CAU Kiel.
- [127] Hüfner, F. P. and M. Schröder: 2002, ‘Prognosegehalt von ifo-Geschäftserwartungen und ZEW-Konjunkturerwartungen: Ein ökonometrischer Vergleich’. *Jahrbücher für Statistik und Nationalökonomie* **222**(3), 316–336.

- [128] Inklaar, R., J. Jacobs, and W. Romp: 2004, ‘Business Cycle Indexes: Does a Heap of Data Help?’. *Journal of business cycle measurement and analysis* **3**, 309–336.
- [129] Jeffreys, H.: 1961, *Theory of probability*. Oxford: Clarendon Press.
- [130] Jevons, W. S.: 1884, ‘Comercial Crises and Sunspots’. In: H. S. Foxwell (ed.): *Investigations in Currency and Finance*. London: MacMillan and Co.
- [131] Johnston: 1974, ‘A note on the estimation and prediction inefficiency of dynamic estimators’. *International Economic Review* **15**, 251–255.
- [132] Judd, J. P. and G. D. Rudebusch: 1998, ‘Taylors Rule and the Fed: 19701997’. *FRBSF Economic Review* **3**.
- [133] Juglar, C.: 1863, ‘Crises Commerciale - Auteur d ’un ouvrage sur les Crises commerciales et leur retour priodique en France, en Angleterre et aux Etats-Unis’. In: M. M. Block (ed.): *Dictionnaire General de la Politique*. Strasbourg: Imprimerie de Veuve Berger-Levrault.
- [134] Kähler, J. and V. Marnet: 1994, ‘International Business Cycles and Long-Run Growth: an Analysis with Markov-Switching and Cointegration Methods’. In: K. F. Zimmermann (ed.): *Output and employment fluctuations*. Heidelberg: Physica-Verlag, pp. 157–175.
- [135] Kholodilin, K. A. and B. Siliverstovs: 2006, ‘On the forecasting properties of the alternative leading indicators for the German GDP : recent evidence’. *Journal of Economics and Statistics* **226**(3), 234–259.
- [136] Kiani, K. M. and P. V. Bidarkota: 2004, ‘On Business Cycle Asymmetries in G7 Countries’. *Oxford Bulletin of Economics and Statistics* **66**(3), 333–351.
- [137] Kim, C., C. Nelson, and J. Piger: 2004, ‘The Less-Volatile US Economy: A Bayesian Investigation of Timing, Breadth, and Potential Explanations’. *Journal of Business and Economic Statistics* **22**, 80–93.
- [138] Kim, C.-J.: 1994, ‘Dynamic linear models with Markov-switching’. *Journal of Econometrics* **60**, 1–22.
- [139] Kim, C.-J.: 2004, ‘Markov-switching models with endogenous explanatory variabels’. *Journal of Econometrics* **122**, 127–136.
- [140] Kim, C.-J., J. Morley, and J. Piger: 2005, ‘Nonlinearity and the permanent effects of regressions’. *Journal of applied econometrics* **20**, 291–309.
- [141] Kim, C.-J. and C. R. Nelson: 1999a, ‘Has the U.S. Economy Become more Stable? A Bayesian Approach Based on a Markov-Switching Model of the Business Cycle’. *The Review of Economics and Statistics* **81**(4), 608–616.

- [142] Kim, C.-J. and C. R. Nelson: 1999b, *State-Space models with regime switching*. Cambridge: MIT Press.
- [143] King, R. G. and C. I. Plosser: 1994, ‘Real Business Cycles and the Test of the Adelmans’. *Journal of Monetary Economics* **33**, 405–438.
- [144] Kitchin, J.: 1923, ‘Cycles and Trends in Economic Factors’. *The Review of Economic Statistics* **5**(1), 10–16.
- [145] Knüppel, M.: 2005, *Non-Normalities of the Business Cycle*. Berlin: Logos.
- [146] Kondratieff, N.: 1926, ‘Die langen Wellen der Konjunktur’. *Archiv für Sozialwissenschaft und Sozialpolitik* **56**, 573–609.
- [147] Koop, G.: 2003, *Bayesian econometrics*. Chichester [u.a.]: Wiley.
- [148] Koop, G. and S. M. Potter: 1999, ‘Bayes factors and nonlinearity: Evidence from economic time series’. *Journal of Econometrics* **88**, 251–281.
- [149] Koopmans, T. C.: 1947, ‘Measurement Without Theory’. *The Review of Economic Statistics* **29**(3), 161–172.
- [150] Kose, M. A., C. Otrok, and C. H. Whiteman: 2003, ‘International business cycles : world, region, and country-specific factors’. *The American Economic Review* **93**(4), 1216–1239.
- [151] Krolzig, H.-M.: 1997, *Markov-Switching Vector Autoregressions*. Springer.
- [152] Kuzin, V.: 2006, ‘The inflation aversion of the Bundesbank: A state space approach’. *Journal of Economic Dynamics and Control* **30**, 1671–1686.
- [153] Kuznets, S.: 1930a, ‘Equilibrium Economics and Business-Cycle Theory’. *The Quarterly Journal of Economics* **44**(3), 381–415.
- [154] Kuznets, S.: 1930b, ‘Static and Dynamic Economics’. *The American Economic Review* **20**(3), 426–441.
- [155] Lucas, R. E.: 1981, *Studies in Business Cycle Theory*. Oxford: Basil Blackwell.
- [156] Lucke, B. and M. Knüppel: 2002, ‘Unternehmensgrößenklassen im ifo-Konjunkturttest: Eine Burns-Mitchell-Analyse’.
- [157] Mankiw, N., D. Runkle, and M. Shapiro: 1984, ‘Are Preliminary Announcements of the Money Stock Rational Forecasts?’. *Journal of Monetary Economics* **14**, 15–27.
- [158] Mankiw, N. G. and M. D. Shapiro: 1986, ‘News or Noise: An Analysis of GDP revisions’. Nber, Survey of Current Business. 20-25.

- [159] Marcellino, M.: 2006, *Handbook of Economic Forecasting*, Vol. 1, Chapt. Leading indicators, pp. 879–960. Amsterdam [u.a.]: North-Holland.
- [160] Marcellino, M., J. H. Stock, and M. W. Watson: 2006, ‘A comparison of direct and iterated multistep AR methods for forecasting macroeconomic time series’. *Journal of Econometrics* **135**, 499–526.
- [161] Mariano, R. and Y. Murasawa: 2003, ‘A new coincident index of business cycles based on monthly and quarterly series’. *Journal of Applied Econometrics* **18**, 427–443.
- [162] Marx, K.: 1867, *Das Kapital: Kritik der politischen Ökonomie*, Vol. 1. Hamburg: Meissner.
- [163] McConnell, M. and G. Perez-Quiros: 2000, ‘Output Fluctuations in the United States: What has Changed Since the Early 1980’s?’. *American Economic Review* **90**, 1464–1476.
- [164] McCracken, M. W.: 1999, ‘Asymptotics for Out of Sample Tests of Causality’. mimeo.
- [165] McQueen, G. and S. Thorley: 1993, ‘Asymmetric business cycle turning points’. *Journal of Monetary Economics* **31**, 341–362.
- [166] Metropolis, N., A. Rosenbluth, M. Rosenbluth, A. Teller, and E. Teller: 1953, ‘Equation of State Calculations by Fast Computing Machines’. *Journal of Chemical Physics* **21**, 1087–1092.
- [167] Mills, T. and P. Wang: 2003, ‘Have Output Growth Rates Stabilized? Evidence from the G-7 Economies’. *Scottish Journal of Political Economy* **50**, 232–246.
- [168] Mitchell, J., R. J. Smith, M. R. Weale, S. Wright, and E. L. Salazar: 2005, ‘An indicator of monthly GDP and an early estimate of quarterly GDP growth’. *The Economic Journal* **115**, 108–129.
- [169] Moore, G. H. and J. Shiskin: 1967, ‘Indicators of business expansion and contractions’. Occasional paper 103, National Bureau of Economic Research, New York.
- [170] Morley, J. and J. Piger: 2004, ‘The Importance of Nonlinearity in Reproducing Business Cycle Features’. Federal Reserve Bank of St.Louis, Working Paper,032A.
- [171] Nelson, C. R. and C. I. Plosser: 1982, ‘Trends and Random Walks in Macroeconomic Time Series: Some Evidence and Implications’. *Journal of Monetary Economics* **10**, 139–162.
- [172] Newey, W. K. and K. D. West: 1987, ‘A simple, positive definite, heteroskedasticity and autocorrelation consistent covariance matrix’. *Econometrica* **55**(3), 703–708.
- [173] Nunes, L.: 2005, ‘Nowcasting quarterly GDP growth in a monthly coincident indicator model’. *Journal of Forecasting* **24**, 575–592.

- [174] Otrok, C. and C. H. Whiteman: 1998, ‘Bayesian leading indicators : measuring and predicting economic conditions in Iowa’. *International Economic Review* **39**(4), 997–1014.
- [175] Owyang, M. T. and G. Ramey: 2004, ‘Regime switching and monetary policy measurement’. *Journal of Monetary Economics* **51**, 1577–1597.
- [176] Pesaran, M. H. and S. M. Potter: 1997, ‘A floor and ceiling model of US output’. *Journal of Economic Dynamics and Control* **21**, 661–695.
- [177] Plosser, C. I. and K. G. Rouwenhorst: 1994, ‘International term structures and real economic growth’. *Journal of monetary economics* **33**, 133–155.
- [178] Potter, S. M.: 1995, ‘A Nonlinear Approach to US GNP’. *Journal of Applied Econometrics* **10**(2), 109–125.
- [179] Proietti, T.: 2006, ‘Temporal disaggregation by state space methods: Dynamic regression methods revisited’. *Econometrics Journal* **9**, 357–372.
- [180] Proietti, T. and F. Moauro: 2006, ‘Dynamic factor analysis with non-linear temporal aggregation constraints’. *Applied Statistics* **55**(2), 281–300.
- [181] R ath, N. and A. Braakmann: 2006, ‘Vergleichbare Zeitreihen der Volkswirtschaftlichen Gesamtrechnungen’. *Wirtschaft und Statistik* **10**, 1003–1020.
- [182] Razzak, W. A.: 2001, ‘Business Cycle Asymmetries: International Evidence’. *Review of Economic Dynamics* **4**, 230–243.
- [183] Richard, J.-F.: 1995, ‘Simulation Techniques’. In: L. Matyas and P. Sevestre (eds.): *The Econometrics of Panel Data*. Dordrecht: Kluwer Academic Publishers, pp. 618–638.
- [184] Romer, D.: 2001, *Advanced Macroeconomics*. London: McGraw-Hill Book Co.
- [185] Sachverständigenrat zur Begutachtung der gesamtwirtschaftlichen Entwicklung: 2002, *Zwanzig Punkte für Beschäftigung und Wachstum*, Jahresgutachten 2002/2003. Stuttgart: Metzler-Poeschel.
- [186] Sargent, T. J. and C. A. Sims: 1977, ‘Business cycle modeling without pretending to have to much a priori economic theory’. In: C. A. Sims (ed.): *New Methods in Business Cycle Research*. Federal Reserve Bank of Minneapolis.
- [187] Schrimpf, A. and Q. Wang: 2007, ‘Is Less More? Alternative Yield Curve Measures and their Time-varying Predictive Content for Real Activity’. Working paper, Centre for European Economic Research (ZEW).

- [188] Schumpeter, J.: 1939, *Business Cycles. A Theoretical, Historical and Statistical Analysis of the Capitalist Process*. London: McGraw-Hill Book Co.
- [189] Schwarz, G.: 1978, ‘Estimating the Dimension of a Model’. *The Annals of Statistics* **6**(2), 461–464.
- [190] Shapiro, S. S. and M. B. Wilk: 1972, ‘An Analysis of Variance Test for the Exponential Distribution’. *Technometrics* **14**(2), 355–370.
- [191] Shephard, N.: 1994, ‘Partial non-Gaussian state space’. *Biometrika* **81**, 115–131.
- [192] Sichel, D. E.: 1993, ‘Business Cycle Asymmetry: A Deeper Look’. *Economic Inquiry* **31**(2), 224–236.
- [193] Simkins, S. P.: 1994, ‘Do real business cycle models really exhibit business cycle behavior?’. *Journal of Monetary Economics* **33**, 381–404.
- [194] Sims, C. A. and T. Zha: 2006, ‘Were There Regime Switches in U.S. Monetary Policy?’. *American Economic Review* **96**, 54–81.
- [195] Spearman, C.: 1904, “‘General intelligence’ objectively determined and measured’. *American Journal of Psychology* **15**, 201–293.
- [196] Statistisches Bundesamt: 2002, ‘Volkswirtschaftliche Gesamtrechnung – Inlandsprodukt und Nationaleinkommen’. Methoden und Verfahren.
- [197] Statistisches Bundesamt: 2007, ‘Kurznachrichten’. *Wirtschaft und Statistik* **8**, 731.
- [198] Stephens, M. A.: 1978, ‘On the W Test for Exponentiality with Origin Known’. *Technometrics* **20**(1), 33–35.
- [199] Stern, S.: 1997, ‘Simulation-Based Estimation’. *Journal of Economic Literature* **35**, 2006–2039.
- [200] Stock, J. H. and M. W. Watson: 1989, ‘New indexes of coincident and leading indicators’. In: O. Blanchard and S. Fischer (eds.): *NBER Macroeconomics Annual*. Cambridge: MA: The MIT Press.
- [201] Stock, J. H. and M. W. Watson: 1991, ‘A probability model of coincident economic indicators’. In: K. Lahiri and G. H. Moore (eds.): *Leading Economic Indicators: New Approaches and Forecasting Records*. Cambridge University Press, pp. 63–89.
- [202] Stock, J. H. and M. W. Watson: 2002a, ‘Has the Business Cycle Changed and Why?’. Harvard University, Department of Economics.

- [203] Stock, J. H. and M. W. Watson: 2002b, ‘Macroeconomic Forecasting Using Diffusion Indexes’. *Journal of Business and Economic Statistics* **20**, 147–162.
- [204] Stock, J. H. and M. W. Watson: 2003a, ‘How did leading indicator forecasts perform during the 2001 recession?’. *Federal Reserve Bank of Richmond Economic Quarterly* **89**(3), 71–90.
- [205] Stock, J. H. and M. W. Watson: 2003b, ‘Understanding Changes in International Business Cycle Dynamics’. Harvard University, Department of Economics.
- [206] Tanner, M. A. and W. H. Wong: 1987, ‘The Calculation of Posterior Distribution by Data Augmentation’. *Journal of the American Statistical Association* **82**(398), 528–540.
- [207] Taylor, J. B.: 1993, ‘Discretion versus policy rules in practice’. *Carnegie-Rochester Conference Series on Public Policy* **39**, 195–214.
- [208] Thurstone, L. L.: 1947, *Multiple factor analysis*. Chicago: University of Chicago Press.
- [209] Valente, G.: 2003, ‘Monetary policy rules and regime shifts’. *Applied Financial Economics* **13**, 525–535.
- [210] Venetis, I. A., I. Paya, and D. A. Peel: 2003, ‘Re-examination of the predictability of economic activity using the yield spread: a nonlinear approach’. *International review of economics and finance* **12**, 187–206.
- [211] Wallis, K. F.: 2003, ‘Chi-squared tests of interval and density forecasts, and the Bank of Englands fan charts’. *International Journal of Forecasting* **19**, 165–175.
- [212] Watson, M. W.: 1994, ‘Business-Cycle Durations and Postwar Stabilization of the U.S. Economy’. *The American Economic Review* **84**(1), 24–46.
- [213] Watson, M. W. and R. F. Engle: 1983, ‘Alternative algorithms for the estimation of dynamic factor, mimic and varying coefficient regression models’. *Journal of Econometrics* **23**(3), 385–400.
- [214] Weber, M. and V. Hofmann: 2006, *Potenzialwachstum in Deutschland: Bestandsaufnahme und wirtschaftspolitische Handlungsempfehlungen*. Köln: Kölner Univ.-Verlag.
- [215] Wright, J. H.: 2006, ‘The Yield Curve and Predicting Recessions’. Finance and Economics Discussion Series 07, Federal Reserve Board.

Lebenslauf

Persönliche Daten

Name	Jens Hogrefe
Geburtsdatum	30.03.1979
Geburtsort	Rotenburg/Wümme
Staatsangehörigkeit	Deutsch
Familienstand	Ledig

Ausbildung

Juli 1998	Abitur am Domgymnasium Verden
Okt. 1999 - Sep. 2001	Studium der Volkswirtschaftslehre an der Ruprecht-Karls-Universität zu Heidelberg
Okt. 2001 - Aug. 2004	Studium der Volkswirtschaftslehre mit Schwerpunkt Quantitative Wirtschaftsforschung an der Christian-Albrechts-Universität zu Kiel Abschluss: Diplom-Volkswirt, Erich-Schneider-Preis für die beste Diplomprüfung im SoSe 2004
Okt. 2004 - Mai 2008	Doktorandenstudium im Rahmen der Programms "Quantitative Economics" der CAU Abschluss: Promotion zum Dr. sc. pol.

Praktische Tätigkeiten

Jul. 1998 - Jul. 1999	Zivildienst im Städtischen Krankenhaus Verden
Feb. - Apr. 2001	Praktikum im damaligen Bundesministerium für Wirtschaft und Technologie, Berlin
Nov. 2001 - Apr. 2004	Wissenschaftliche Hilfskraft an der Forschungsstelle für nationale und internationale Finanzordnung des Lorenz-von-Stein-Instituts für Verwaltungswissenschaften an der Christian-Albrechts-Universität zu Kiel
Okt. 2003 - März 2004	Tutor für die Veranstaltung Methodenlehre der Statistik II des Grundstudiums an der Christian-Albrechts-Universität zu Kiel
Mai 2004 - April 2008	Wissenschaftlicher Mitarbeiter am Lehrstuhl für Statistik und empirische Wirtschaftsforschung der Christian-Albrechts-Universität zu Kiel
Mai 2008 -	Wissenschaftlicher Angestellter am Institut für Weltwirtschaft, Kiel

Vorträge auf Tagungen und Konferenzen

- 27.10.2004 Umverteilungswirkungen der Familienförderung - eine Inzidenzanalyse auf Basis der EVS 1998, Jour Fixe des Zentrums für Sozialpolitik, Bremen
- 08.09.2005 Das Kiel Tax-Benefit Microsimulation Model (KiTs): Methodik, Anwendung und Ergebnisse (zus. mit Thomas Drabinski), Symposium des Lorenz-von-Stein-Instituts an der Christian-Albrechts-Universität zu Kiel: Das deutsche Steuer- und soziale Sicherungssystem: Reformvorschläge und deren finanzielle Auswirkungen, Kiel
- 27.09.2006 The Decline in German Output Volatility: A Bayesian Analysis, Jahrestagung des Verein für Socialpolitik, Bayreuth
- 01.12.2006 The yield spread and GDP growth - time varying leading properties and the role of monetary policy, DIW Macroeconometric Workshop, Berlin
- 27.08.2007 The yield spread and GDP growth - time varying leading properties and the role of monetary policy, Econometric Society European Meeting, Budapest
- 24.09.2007 Forecasting Data Revisions of GDP - a mixed frequency approach, Statistische Woche, Kiel
- 10.10.2007 Forecasting Data Revisions of GDP - a mixed frequency approach, Jahrestagung des Verein für Socialpolitik, München
- 30.11.2007 Forecasting Data Revisions of GDP - a mixed frequency approach, Forschungsseminar der Deutschen Bundesbank, Frankfurt

Lehrtätigkeit

- Übung zur Vorlesung Methodenlehre der Statistik I (SoSe 06 und SoSe 07)
- Übung zur Vorlesung Methodenlehre der Statistik II (WiSe 06/07 und WiSe 07/08)
- Statistik mit Excel (jedes Semester seit SoSe 05)
- Übung zur Vorlesung Statistik für Fortgeschrittene I (SoSe 04 und SoSe 05)
- Übung zur Vorlesung Statistik für Fortgeschrittene II (WiSe 04/05 und WiSe 05/06)
- Übung zur Vorlesung Mikroökonomie (WiSe 04/05 und WiSe 05/06)
- Übung zur Vorlesung Statistics for Financial Markets (WiSe 06/07)
- Tutorial "Markov-Switching Models" im Rahmen des Advanced Studies Program am Institut für Weltwirtschaft Kiel 2004/05

Publikationsliste

Monographien

- Umverteilungswirkungen der Familienförderung - eine Inzidenzanalyse für die Bundesrepublik Deutschland, Lorenz-von-Stein-Institut, Kiel, 2005

Beiträge in Sammelbänden

- Verteilungseffekte der Familienförderung, In: Seidl, Christian und Jickeli, Joachim (Hrsg.): Steuern und Soziale Sicherung in Deutschland, Springer Verlag, 2006

Veröffentlichungen in referierten Zeitschriften

- Dynamic Multi-Sector CGE Modeling and the Specification of Capital: Comment on Farmer and Wendner (2004), mit C. Aßmann, erscheint demnächst in Structural Change and Economic Dynamics
- Forecasting Data Revisions of GDP - a mixed frequency approach, erscheint demnächst in Advances in Statistical Analysis

Diskussionspapiere

- The Decline in German Output Volatility: A Bayesian Analysis, Economic Working Paper No. 2006-02, mit C. Aßmann und R. Liesenfeld
- The yield spread and GDP growth - time varying leading properties and the role of monetary policy, Economic Working Paper No. 2007-12