

056V

Bundesanstalt für



Agrarwirtschaft

# **DIE SAISONALE VERTEILUNG DER MILCHANLIEFERUNG**

## **SEASONALITY AND FORECASTING OF MILK DELIVERIES**

KARL M. ORTNER

Schriftenreihe Nr. 87

Wien 1999



Zugangsdatum	6.10.98
Erwerbsart	G
Zugangsnummer	44084
Preis	—
Signatur	056 V

ISBN 3 - 901 - 338 - 15 - 2

Eigentümer, Herausgeber, Verlag und Druck: Bundesanstalt für Agrarwirtschaft,  
1133 Wien, Schweizertalstraße 36

## Inhalt

Vorwort	5
1. Problemstellung	7
2. Theoretische Grundlagen	9
2.1 Saisonfigur und Saisonbereinigung	9
2.2. Kausale Modelle	11
2.3. Ein kausales Modell für gleitende Durchschnitte	12
2.4. Partielle Anpassungsmodelle	13
2.5. Die Fehlerkomponente	15
2.6. Genauigkeit der Prognosen	17
2.6. Andere Modelle	18
3. Schätzung der Modellparameter	20
3.1. Das Saisonbereinigungsmodell	20
3.2. Kausale Modelle	21
4. Vorgehensweise	22
4.1. Konventionelle Ermittlung der Saisonfigur	22
4.2. Ermittlung des Saisonbereinigungsmodells	22
4.3. Ermittlung der kausalen Modelle	24
4.4. Auswertung der Ergebnisse	25
5. Datengrundlage	28
6. Ergebnisse	34
6.1. Entwicklung der saisonalen Abweichungen	34
6.2. Saisonbereinigungsmodell	35
6.3. Kausales Modell	35
6.4. Partielles Anpassungsmodell	36
6.5. Vergleich der Schätzergebnisse	37
6.6. Prognosen und Prognosefehler	37
6.7. Vergleich der geschätzten Saisonfiguren	41
6.8. Hochrechnung auf Quotenjahre	43
7. Schlussfolgerungen	49
8. Zusammenfassung	51
Summary	52
9. Literaturverzeichnis	53
10. Anhang	54

## Verzeichnis der Tabellen

1	Milchquoten, Milchanlieferung, Erzeugerpreise und Verbraucherpreisindex	32
2	Jahresdurchschnittswerte von anderen die Milchanlieferung beeinflussenden Variablen	33
3	Statistiken über die Regressionsgleichungen der Modelle	37
4	Saisonale Abweichungen der Milchanlieferung in Österreich von der glatten Komponente	42

5	Ab April kumulierte Prozentanteile der Monate des Wirtschaftsjahres 1998/99 an der jährlichen Milchanlieferung	44
6	Konfidenzintervalle und Standardfehler von Hochrechnungen der Milchanlieferung mit Hilfe der saisonalen Verteilung des Saisonbereinigungsmodells	46
7	Standardabweichungen der Prognosefehler aus dynamischen Prognosen über mehrere Monate der Referenzperiode (Jänner 1983 bis Juni 1998)	47
A1	Regressionskoeffizienten des Saisonbereinigungsmodells	55
A2	Regressionskoeffizienten des kausalen Modells	57
A3	Regressionskoeffizienten des partiellen Anpassungsmodells	59
A4	Berechnung der Superabgabe für 1997/98	61
A5	Berechnung der Superabgabe für 1998/99	61

## Verzeichnis der Abbildungen

1	Milchlieferleistung dekadewise 1991-1994	27
2	Milchanlieferung 1997, Verteilung nach Bundesländern	28
3	Einzelrichtmengen und Milchanlieferung 1979-1997	29
4	Abweichungen der dreijährigen Mittelwerte der saisonalen Abweichungen von ihrem Durchschnitt 1/1981-6/1998	33
5	Prognosefehler der Modelle in Abhängigkeit von der Verfügbarkeit von Daten	38
6	Die durchschnittlichen absoluten Prognosefehler der drei Modelle in Abhängigkeit von der Länge des Prognosehorizontes	39
7	Die Standardabweichung der Prognosefehler der drei Modelle in den Monaten Juli bis Dezember 1998 in Abhängigkeit von der Länge des Prognosehorizontes	39
8	Abweichungen von der glatten Komponente in den drei Modellen	41
9	Unterschiede zwischen den Saisonfiguren der ökonometrischen Modelle und den durchschnittlichen saisonalen Abweichungen	41
10	Unterschiede zwischen den ab April kumulierten Anteilen an der Milchanlieferung	43

## Verzeichnis der Abkürzungen

ALFIS	Allgemeines Land- und Forstwirtschaftliches Informationssystem
AMA	Agrarmarkt Austria
EU	Europäische Union
GLS	Generalized least squares
MAPE	Mean average prediction error
OLS	Ordinary least squares
RMSE	Root mean square error



## Vorwort

*1-2 zu können*

Die Milchrichtmengenregelung wurde in Österreich 1978 eingeführt und erfuhr seither einige Veränderungen. Zu Beginn wurden Härtefälle bereinigt und Überlieferungen durch Vergabe neuer Einzelrichtmengen an die betroffenen Bauern vermindert; später kaufte man Quoten zurück und bot den Lieferanten die Teilnahme an einer freiwilligen Lieferverzichtsaktion an, um den Umfang der Exporte von Milchprodukten einzuschränken. Die Kosten dieser Exporte waren ein großes Problem: Sie belasteten nicht nur das Budget, sondern auch die Lieferanten, die durch variable Preisabschläge (Absatzförderungsbeiträge) dazu beitrugen, dass die Kosten gedeckt werden konnten. Seit dem Beitritt zur EU sind die Preise für Rohmilch deutlich gesunken; dennoch lieferten die österreichischen Milchbauern 1997 und 1998 mehr Milch als auf Grund der nationalen Milchquoten vorgesehen war. Solche Überlieferungen werden von der Europäischen Union mit „Zusatzabgaben“ („Superlevy“) von € 0,3563 je Liter Nettoüberlieferung der nationalen Quote bestraft (1998: 527 Mio. ~~ATS~~). *aber*

Eine Nettoüberlieferung und die damit verbundenen Abgaben sollten daher vermieden werden; aber die Überlieferung einer individuellen Quote ist wirtschaftlich sinnvoll, wenn gleichzeitig Unterlieferungen in derselben Höhe vorliegen. Um zu bestimmen, welcher Spielraum für zusätzliche Lieferungen besteht und wie groß das Risiko ist, mehr oder weniger Zusatzabgabe zahlen zu müssen, benötigen die Milchlieferanten nicht nur Prognosen über die zu erwartende nationale Anlieferungsmenge, sondern auch eine Vorstellung darüber, wie genau diese Prognosen sind. Die vorliegende Studie beschreibt, welche Modelle zur Prognose der Milchanlieferung verwendet werden könnten, spezifiziert und schätzt bestimmte Prognosemodelle für Österreich und untersucht die Genauigkeit von Prognosen, die mit ihnen erstellt wurden. Sie zeigt damit einerseits den Weg zu besseren Prognosen und verweist andererseits darauf, deren Unsicherheiten zu beachten. *David*

*-1.57*

Wien, August 1999

HR DI Dr. Hubert Pflingstner



# 1. Problemstellung

Die Milchanlieferung<sup>1</sup> unterliegt auf Grund von fütterungs- und haltungstechnischen Produktionsbedingungen beträchtlichen saisonalen Schwankungen. Dafür verantwortlich ist vor allem die unterschiedliche Futtergrundlage in den verschiedenen Jahreszeiten: (das frische) saftige Grünfutter im April und Mai, das schon zähere, überständige Gras und der nährstoffärmere zweite Schnitt im Sommer, allenfalls der dritte Schnitt und die Umstellung der Verdauung auf beigefüttertes Feldfutter (z.B. Grünmais, Raps, Klee, Rüben) im Herbst sowie im Winter die noch viel einschneidendere Umstellung auf Silofutter und Heu, dessen Qualität sehr von den Witterungsverhältnissen zur Zeit der Ernte abhängt.

Zu diesen saisonalen Einflussfaktoren auf die Milchleistung der Kühe kommen noch die unternehmerischen Entscheidungen der Milcherzeuger. Aus der Summe dieser Einflüsse und Entscheidungen resultiert die Milchanlieferung. Die Milcherzeuger entscheiden über die Zusammensetzung des Futters und die Höhe der Kraftfutterbeigaben, über die Zahl der zu haltenden Milchkühe und über die Verwendung der Kälber; diese können geschlachtet, mit Milch gemästet oder zu Masttieren oder zur Bestandesergänzung aufgezogen werden. Die Erzeuger reagieren mit diesen Entscheidungen auf aktuelle Marktverhältnisse und politische Rahmenbedingungen; unter diesen besonders wichtig sind die einzelbetrieblich festgelegten Milchrichtmengen, die die Menge beschränken, die ein Landwirt im Laufe eines Wirtschaftsjahres (bis 1994 von Juli bis Juni, seit 1995: April bis März) zum mehr oder weniger regulierten Marktpreis abzüglich eines Allgemeinen Absatzförderungsbeitrags verkaufen konnte. Für Milch, die ein Erzeuger darüber hinaus lieferte, musste er einen „Zusätzlichen Absatzförderungsbeitrag“ entrichten, der diese Lieferungen unrentabel machte.

Erst gegen Ende des jeweiligen Quotenjahres stellt sich heraus, ob die jährliche Richtmenge mit den gelieferten Mengen in Einklang gebracht werden kann. In diesen Monaten kann der Landwirt versuchen, mehr oder weniger zu liefern, um seine Richtmenge zu erfüllen, ohne sie zu überschreiten. Wäre ihm die saisonale Verteilung der Milchleistung auf die einzelnen Monate bekannt, und wäre sie noch dazu stabil, dann könnte er seine jährliche Richtmenge auf die Monate verteilen und damit feststellen, wie viel er in den einzelnen Monaten liefern soll. Er könnte die Soll-Lieferungen mit den tatsächlichen Lieferungen bis zu diesem Monat vergleichen und somit ständig kontrollieren, ob er seine Richtmengen über- oder unterliefert, und seine Milchlieferungen ständig anpassen, um Überlieferungen am Ende des Quotenjahres zu vermeiden.

Durch die Einführung der EU-Marktordnungen im Jahr 1995 wurde ein Teil des Problems der milcherzeugenden Betriebsleiter auf die nationale Ebene verlagert, denn seither gibt es zusätzlich zur einzelbetrieblichen Milchrichtmenge eine nationale Referenzmenge, die von der Gesamtheit der Milcherzeuger einzuhalten ist. Der einzelne Landwirt hat keinen Nachteil, wenn er seine Milchrichtmenge überschreitet, sofern die gelieferten Mengen aller Landwirte in Summe die nationale Referenzmenge nicht überschreiten. Ob dies der Fall ist, muss am Markt beobachtet und vorausschauend beurteilt werden. Wenn auf nationaler Ebene bekannt wäre, welche Mengen bis zum jeweiligen Zeitpunkt geliefert werden sollen, könnte man frühzeitig erkennen, ob eine Erfüllung oder Überschreitung der Quote bevorsteht und ob es sich lohnt, den Bauern eine Drosselung ihrer Milchanlieferung zu empfehlen, um ihnen die Zahlung „Zusätzlicher Absatzförderungsbeiträge“ („Superabgaben“) zu ersparen.

---

<sup>1</sup> Das sind die Lieferungen von Milch von den Milcherzeugern an die Be- und Verarbeitungsbetriebe. Synonyme dafür sind Milchanlieferung, Milchlieferungen.

Voraussetzung für einen Soll-Ist-Vergleich ist die Kenntnis der saisonalen Verteilung der Milch-anlieferung: Die Soll-Werte ergeben sich aus einer entsprechenden Verteilung der jährlichen Referenzmenge auf die Saisonen (Monate oder Dekaden). Die dabei zu verteilende Referenzmenge muss nicht nur die ursprünglich zur Verfügung stehende A-Quote (Anlieferungsquote), sondern auch die zu erwartenden zeitweisen Übertragungen von D-Quoten (Direktvermarktungsquoten) zu A-Quoten und umgekehrt berücksichtigen. Die für die Berechnung der Superabgabe endgültig wirksame A-Quote ist erst nach Abschluss dieser Übertragungen (im folgenden Quotenjahr) bekannt; ebenso verhält es sich mit dem Fettgehalt der angelieferten Milch, der ebenfalls ausgeprägten saisonalen Schwankungen unterliegt und bestimmt, mit welchem Korrekturfaktor die Milchlieferung multipliziert werden muss, um sie mit der Referenzmenge vergleichbar zu machen.

Im vorliegenden Beitrag soll die Verteilung der Milchlieferungen auf die einzelnen Monate geschätzt und prognostiziert werden. Dabei wird die Hypothese geprüft, wonach die Saisonfigur der Milchlieferung von politischen Ereignissen beeinflusst wird. Wenn sie sich aus verschiedenen Einflüssen zusammensetzt, dann entsteht nach Abzug des Einflusses (markt-) politisch motivierter Ereignisse eine andere, vielleicht stabilere Saisonfigur, die nur mehr auf Witterungsbedingungen zurückzuführen ist. Sollte diese bereinigte Saisonfigur jedoch ebenso instabil sein wie die ursprüngliche, dann würde es genügen, die Saisonfigur für den Soll-Ist-Vergleich mit Hilfe einer konventionellen Saisonbereinigung zu bestimmen. Weiters wäre zu prüfen, inwieweit eine Änderung der Saisonfigur im Lauf der Zeit stattgefunden hat, um sie allenfalls für die Zukunft durch Trendextrapolation genauer prognostizieren zu können.

Im folgenden Abschnitt werden die Möglichkeiten der Bestimmung der saisonalen Komponente einer Zeitreihe und die dabei möglicherweise auftretenden Probleme besprochen. Dies führt zu Modellen, in denen die Saisonfigur explizit angegeben ist, und zum Problem der Schätzung ihrer Parameter. Darauf aufbauend lege ich konkrete Vorgehensweisen zur Ermittlung der Saisonfigur fest und ermittle sie auf Basis der beschriebenen Daten. Die Ergebnisse werden vorgestellt und im Hinblick darauf, inwieweit sie von politischen und wirtschaftlichen Rahmenbedingungen beeinflusst werden, miteinander verglichen und kommentiert. Schlussfolgerungen werden aus den Ergebnissen hinsichtlich zweier Fragen gezogen, nämlich: Wie wirkt sich ihre Verwendung zur Hochrechnung der saisonalen Milchlieferungen auf jene des gesamten Quotenjahres aus, und wie genau sind diese Hochrechnungen im Vergleich zu den Prognosen mit den ökonometrischen Modellen. Die ökonometrische Analyse wird erschwert durch die Tatsache, dass infolge des EU-Beitritts 1995 nicht nur das Quotenjahr (von Juli bis Juni) auf April bis März umgestellt wurde, sondern auch eine Verhaltensänderung der Milchlieferanten eingetreten sein könnte; in dieser Studie wird angenommen, daß die Milchlieferanten vor und nach dem Beitritt zur EU auf Änderungen der Rahmenbedingungen in gleicher Weise reagieren.

## 2. Theoretische Grundlagen

### 2.1 Saisonfigur und Saisonbereinigung

Bei der Saisonbereinigung einer Zeitreihe  $y$  wird angenommen, dass sich diese aus drei Elementen zusammensetzt: einer glatten Komponente  $g$ , einer um Null verteilten saisonalen Komponente  $s$  und einer um Null verteilten Fehler- oder Zufallskomponente (oder -variablen)  $u$ .

$$(1) \quad y_t = s_{it} + g_t + u_t$$

Darin bezeichnet  $t$  einen Monat (oder eine andere sich jährlich wiederholende Zeitspanne: Woche, Dekade, Tertial, Quartal, Halbjahr) und  $s_{it}$  den im Monat  $i$  zum Zeitpunkt  $t$  wirksamen saisonalen Effekt. Wenn  $y_t$  in logarithmischem Maßstab gemessen wird, ist

$$e^{s_{it}}$$

der Saisonindex für die Saison (den Monat)  $i$  zum Zeitpunkt  $t$ .

Die Zeitreihe  $s_{it}$  in  $m$  ( $=12$ ) aufeinander folgenden Monaten ist eine Saisonfigur.

Die saisonbereinigte Reihe ( $y_s$ ) ist definiert als

$$(2) \quad y_s = y_t - s_{it} = g_t + u_t$$

Die saisonale Abweichung ist definiert als:

$$(3) \quad sa_{it} = y_t - g_t = s_{it} + u_t$$

Um eine saisonale Zeitreihe in ihre drei Komponenten zerlegen zu können, bedarf es weiterer Annahmen. Die einfachsten Annahmen, die bei der (konventionellen) Saisonbereinigungsmethode getroffen werden, sind die einer fixen Saisonfigur

$$s_{it} = s_i$$

und die Annahme, dass  $g_t$  der (zentrierte) gleitende Durchschnitt von  $y_t$  über  $m$  Saisonen ist (bei Monatsdaten:  $m = 12$ ). Verfahren, die sich auf diese Annahmen stützen, sind als Datentransformationen in ökonometrischen Computerprogrammen, aber auch im Allgemeinen Land- und Forstwirtschaftlichen Informationssystem (ALFIS) des Bundesministeriums für Land- und Forstwirtschaft, als Saisonbereinigungsverfahren implementiert.

Spezialisierte Saisonbereinigungsprogramme zerlegen eine Zeitreihe dagegen in (üblicherweise die drei oben genannten) Komponenten, von denen mindestens zwei (die glatte und die saisonale) als ARMA-Prozesse<sup>2</sup> beschrieben werden, denen jeweils ein bestimmter Teil der Varianz der Zeitreihe zugeordnet wird (NERLOVE et al. 1979). Auf Grund dieser Annahmen erfolgt die Zerlegung der Zeitreihe mit Hilfe aufwändiger Computerprogramme, die auch eine Bereinigung des Einflusses von arbeitsfreien Wochentagen, Feiertagen u. dgl. auf die Zeitreihe zulassen (WÜGER 1995). Eine Bereinigung der Mengendaten in Schaltjahren kann dagegen auf einfache Weise, z.B. durch Verminderung der Werte im Februar auf 28 Tage (durch Multiplikation mit dem Faktor 28/29), erfolgen.

Der (zentrierte) gleitende Durchschnitt als Schätzwert für die glatte Komponente existiert nicht bis zum Ende der Zeitreihe. Dies ist ein Nachteil, wenn die saisonale Komponente prognostiziert werden soll. Ein weiterer Nachteil ist, dass, wenn die Anzahl der Saisonen  $m$  durch zwei

---

<sup>2</sup> Autoregressive Moving Average



teilbar ist (was z. B. bei Monatsdaten der Fall ist), der erste gleitende Durchschnitt zu keinem Monat gehört<sup>3</sup>. Er wird erst durch die Berechnung eines gleitenden Durchschnitts aus gleitenden Durchschnitten (z.B. zwischen Juni/Juli und Juli/August) einem Monat zugeordnet. Solche Berechnungen beeinflussen auch die Größe und Verteilung der Fehlervariablen  $u_t$ . Diese beiden Nachteile lassen sich dadurch vermeiden, dass man das gleitende Mittel dem jeweils letzten (aktuellsten) Monat zuordnet, dessen Wert zu seiner Berechnung benötigt wurde. Das so definierte Mittel existiert bis zur jeweils letzten bekannten Beobachtung; die saisonale Abweichung dieser Beobachtung unterscheidet sich jedoch von jener zum zentrierten gleitenden Durchschnitt (siehe die Ergebnisse in Tab. 4), der üblicherweise verwendet wird.

Als Saisonbereinigungsmodell definieren wir in dieser Studie die Gleichung (1) in Verbindung mit der Annahme, dass die glatte Komponente der Zeitreihe  $y$  das Mittel aus dem aktuellen Wert und den  $m-1$  vorher beobachteten Werten von  $y$  ist:

$$(4) \quad y_t = s_{it}^y + \bar{y}_t + u_t^y$$

$$\text{mit} \quad \bar{y}_t = b \sum_{l=0}^{m-1} y_{t-l}$$

$$b = 1/m$$

Zur Berechnung der dazugehörigen Saisonfigur  $s_{it}$  werden die entsprechenden saisonalen Abweichungen vom gleitenden Durchschnitt verwendet. Sie wurden mit dem Superscript  $y$  versehen, um auf ihre Abhängigkeit von der Definition der glatten Komponente als Funktion verzögerter Werte von  $y$  hinzuweisen:

$$(5) \quad sa_{it}^y = y_t - \bar{y}_t = s_{it}^y + u_t^y$$

Die saisonalen Komponenten  $s_{it}$  können unter der Annahme, dass die Saisonfigur konstant ist ( $s_{it} = s_i$ ), aus den (bekannten) saisonalen Abweichungen auf zwei Arten berechnet werden:

- a) unter Minimierung der Absolutwerte von  $u_t$ . Dies entspricht der Annahme einer gleichförmigen Verteilung der  $u_t$ . In diesem Fall ist der Schätzwert für  $s_i$ ,  $\hat{s}_i$ , der Mittelwert der  $sa_{it}$ . Bei arithmetischer Mittelung ist

$$\hat{s}_i = \sum sa_{it} / n$$

mit  $n$  Zahl der Jahre, in denen eine Beobachtung für  $sa_{it}$  vorliegt.

- b) unter Minimierung der Quadrate von  $u_t$ . Dies entspricht der Annahme einer Normalverteilung der  $u_t$ . Diese Schätzung der  $s_i$  erfolgt mittels Regression unter Verwendung von Dummy-(0/1-)Variablen zur Darstellung der  $s_{it}$ .

In beiden Fällen ist

$$\sum u_t = 0$$

Einfache Standardsaisonbereinigungsverfahren gehen nach Methode a) vor. Sie ist z.B. Grundlage für den so genannten „Milchbarometer“ der AMA, der auf dem Durchschnitt der saisonalen Abweichungen in den vergangenen drei Jahren beruht (s. AMA, Marktbericht Milch).

<sup>3</sup> So gehört etwa der Jahresdurchschnitt zu den Monaten Juni und Juli.

Um eine zeitlich variable Saisonfigur zu schätzen, z.B. eine, die einem linearen Trend ( $T_t$ ) folgt, verwendet man für die Saisonindizes in Gleichung (5)

$$(6) \quad s_{it} = s_{i0} + s_{i1} T_t$$

Für Methode b) spricht die realistischere Annahme einer Normalverteilung für die Fehlervariable, d.h. dass kleinere Abweichungen zwischen  $sa_{it}$  und  $s_{it}$  wahrscheinlicher sind als größere. Außerdem liefert eine Regressionsgleichung Angaben über die Genauigkeit der Schätzung (die Verteilung der Prognosefehler  $u_t$ ) und der Schätzwerte  $\hat{s}_{i0}$  und  $\hat{s}_{i1}$  sowie Statistiken darüber, ob einzelne Schätzwerte signifikant von Null verschieden sind, sodass z.B. geprüft werden kann, ob einzelne saisonale Abweichungen von der glatten Komponente tatsächlich einem linearen Trend folgen. Bei Methode a) wird die Frage nach der Genauigkeit der geschätzten  $s_{it}$  stillschweigend übergangen.

## 2.2. Kausale Modelle

Die Beobachtung, dass  $y_t$  in einem bestimmten Monat  $i$  größer oder kleiner ist als  $y_{t+1}$  in einem anderen Monat  $j$ , kann andere Ursachen haben als eine regelmäßige saisonale Komponente: Sie kann z.B. auf eine besondere politische Konstellation zurückzuführen sein. Es ist auch möglich, dass diese Konstellation regelmäßig aufgetreten ist und daher der saisonalen Komponente zuzuordnen ist, dass sie in Zukunft aber möglicherweise nicht mehr auftreten wird, weil die politischen Rahmenbedingungen geändert wurden oder weil sich die Marktlage geändert hat. Z.B. könnten Förderungen, die einen Anstieg (oder eine Senkung) von  $y_t$  in einem bestimmten Monat (oder in mehreren nachfolgenden Monaten) bewirken, entfallen, sodass dieser Anstieg (oder diese Senkung) nicht mehr im selben Ausmaß erwartet werden kann wie bisher. Diese Wirkungen werden bei der Zerlegung einer Zeitreihe in drei Komponenten dadurch berücksichtigt, dass sie der glatten Komponente zugeordnet werden; diese enthält dann Wirkungen, deren Ursachen bekannt sind und deren Einflüsse als separate Komponenten berücksichtigt werden können.

Ein kausales Modell zerlegt eine Zeitreihe somit nicht nur in eine saisonale, eine glatte und eine Fehlerkomponente, sondern in mehr als diese Komponenten: Die saisonale und die Fehlerkomponente erhalten infolge der neuen Zerlegung, bei der die glatte Komponente aufgeteilt wird und in Komponenten zerfällt, die im Zusammenhang mit exogenen Variablen stehen, andere Werte. Die neuen Komponenten sind Funktionen von exogenen Variablen, die eine ursächliche Wirkung auf die abhängige Variable ausüben. Solche Wirkungen können vorübergehend sein und nach wenigen Monaten wieder abklingen, sodass die Werte einer bestimmten Komponente gegen Null gehen, oder sie können bestehen bleiben. Demgemäß wirken sie sich teils auf die Fehlerkomponente und teils auf die (neu zusammengesetzte) glatte Komponente aus. Die glatte Komponente ist eine Funktion von  $k$  exogenen Variablen:

$$(7) \quad g_t^x = a_0 + \sum_{j=1}^k a_j x_{jt}$$

$$\begin{array}{lll} \text{mit} & a_j & (j = 0, 1, \dots, k) \text{ fixe Koeffizienten} \\ & x_j & (j = 1, \dots, k) \text{ exogene Variablen} \end{array}$$

Setzt man diese Formulierung in Gleichung (1) ein, dann erhält man das kausale Modell

$$(8) \quad y_t = s_{it}^x + g_t^x + u_t^x = s_{it}^x + a_0 + \sum_{j=1}^k a_j x_{jt} + u_t^x$$

Das Superscript  $x$  verweist darauf, dass sich die Komponenten des kausalen Modells von jenem des Saisonbereinigungsmodells unterscheiden. Insbesondere die glatten Komponenten unterscheiden sich darin, dass jene des Saisonbereinigungsmodells (4) wesentlich glatter ist. Schließlich handelt es sich bei der Gleichung für  $g_t^y$  um einen autoregressiven Prozess, dessen Parameter  $b$  vorgegebene Gewichte sind, die bewirken, dass sich  $g_t^y$  von Monat zu Monat nur wenig ändern kann. Die variablen Parameter der Gleichung für  $g_t^x$  erlauben dagegen, dass sich jede Änderung von  $x_j$  auf  $g_t^y$  in bestimmtem Umfang,  $a_j$ , unmittelbar (in der Zeitspanne  $t$ ) auswirkt<sup>4</sup>.

### 2.3. Ein kausales Modell für gleitende Durchschnitte

Zwischen der glatten Komponente des Saisonbereinigungsmodells (4) und dem kausalen Modell (8) lässt sich allerdings ein enger Zusammenhang herstellen. Setzt man nämlich Gleichung (8) in Gleichung (4) ein, dann erhält man

$$(9) \quad g_t^y = \bar{y}_t = b \sum_{r=0}^{m-1} y_{t-r} = b \sum_{r=0}^{m-1} \left( s_{t,t-r}^x + a_0 + \sum_{j=1}^k a_j x_{j,t-r} + u_{t-r}^x \right)$$

Definitionsgemäß sind aber

$$\sum_{r=0}^{m-1} s_{t,t-r} = 0$$

$$\sum_{r=0}^{m-1} b = 1$$

Außerdem sind die  $u_t$  um Null verteilt, sodass der Mittelwert von  $m$   $u_t$ -s nahezu Null ist:

$$\sum_{r=0}^{m-1} u_{t-r}^x \equiv 0$$

Wir erhalten daher

$$(10) \quad g_t^y = \bar{y}_t \equiv a_0 + \sum_{r=0}^{m-1} b \sum_{j=1}^k a_j x_{j,t-r} = a_0 + \sum_{j=1}^k a_j \bar{x}_{jt}$$

mit

$$\bar{x}_{jt} = \sum_{r=0}^{m-1} b x_{j,t-r}$$

und

$$b = 1/m$$

Die glatte Komponente des Saisonbereinigungsmodells kann also nahezu vollständig aus jenen exogenen Variablen ermittelt werden, die die glatte Komponente des kausalen Modells (7) bestimmen. Diese ist - wie bereits erwähnt - viel variabler, weil sie nicht von den gleitenden Mitteln der exogenen Variablen abhängt, sondern von deren aktuellen und/oder verzögerten Werten:

$$g_t^x = a_0 + \sum_{j=1}^k a_j x_{jt}$$

Im Vergleich dazu ist

<sup>4</sup>  $x_{jt}$  kann hier (noch) eine verzögerte Variable darstellen, also eine, die den Zustand von  $x$  einige Monate vor  $t$  anzeigt.



$$(11) \quad g_t^y \cong a_0 + \sum_{j=1}^k a_j \bar{x}_{jt} = a_0 + \sum_{r=0}^{m-1} \sum_{j=1}^k b a_j x_{j,t-r}$$

Die in (11) angeschriebenen mathematischen Formulierungen für die glatte Komponente deuten bereits an, dass diese noch detaillierter modelliert werden kann. Dazu lösen wir die Konstanz des Koeffizienten  $b$  auf und erlauben unterschiedliche Werte für die jeweiligen Verzögerungen  $r$  ( $b_r$ ); weiters lösen wir die Beschränkung der Zahl der Verzögerungen ( $m-1$ ) auf und erweitern sie auf  $q$ . Mit den Koeffizienten  $a_{jr} = b_r^* a_j$  und einer neuen Fehlervariable  $v$  erhalten wir eine sehr flexible Form eines **kausalen Modells für gleitende Mittel**:

$$(12) \quad \bar{y}_t = a_0 + \sum_{r=0}^q \sum_{j=1}^k a_{jr} x_{j,t-r} + v_t$$

wobei  $v_t$  eine Fehlervariable mit  $E(v_t) = 0$

Die Zahl der freien Parameter dieses Modells ist mit  $k^*(q+1)+1$  allerdings ziemlich hoch, sodass die Zahl der Freiheitsgrade im verfügbaren Datensatz wahrscheinlich nicht reichen wird, um alle diese Parameter statistisch schätzen zu können. Um diesem Problem beizukommen, müssen subjektive Annahmen darüber getroffen werden, welche Parameter Null sind, welche gleich groß sind, in einem bestimmten Verhältnis zueinander stehen oder einem bestimmten Muster gehorchen.

Das Ergebnis (12) kann man natürlich auch zur Erweiterung des kausalen Modells (8) nützen; dazu setzt man den deterministischen Teil von (12) für die glatte Komponente in Gleichung (1) ein, subsumiert den stochastischen Teil ( $v_t$ ) unter  $u_t$  und erhält eine sehr flexible Form des kausalen Modells, mit entsprechend vielen Parametern  $a_{jr}$ :

$$(13) \quad y_t = s_{it} + a_0 + \sum_{r=0}^q \sum_{j=1}^k a_{jr} x_{j,t-r} + u_t$$

## 2.4. Partielle Anpassungsmodelle

Um darzustellen, dass ein Anpassungsprozess, der in Periode  $t$  beginnt, nicht gleich in derselben Periode abgeschlossen wird, benützen wir den die gleitende Komponente repräsentierenden Teil der Gleichung (12) zur Darstellung des Ziels dieses Anpassungsprozesses, des „gewünschten“ gleitenden Mittels  $g^*$ :

$$(14) \quad g_t^* = a_0 + \sum_{r=0}^q \sum_{j=1}^k a_{jr} x_{j,t-r}$$

$g^*$  ist die bei gegebenen exogenen Variablen  $x_{jt}$  „angestrebte“ gleitende Komponente, die auf Grund der Tatsache, dass zur Entfaltung der Wirkungen der exogenen Variablen ein längerer Zeitraum nötig ist, in der aktuellen Periode  $t$  noch nicht erreicht werden kann. Von einer Periode bis zur nächsten wird daher nur ein Teil  $(1-\lambda)$  der Anpassung an die gewünschte gleitende Komponente vollzogen:

$$(15) \quad g_t - g_{t-1} = (1-\lambda)(g_t^* - g_{t-1}) + u_t$$

mit  $0 \leq \lambda < 1$

und  $u_t$  eine um Null verteilte Fehlervariable

Wäre  $\lambda=1$ , dann gäbe es keine Anpassung, und Änderungen der glatten Komponente würden einem Zufallsprozess folgen; dieser Fall wird ausgeschlossen. Die Auflösung von Gleichung (15) nach  $g_t$  ergibt:

$$g_t = \lambda g_{t-1} + (1-\lambda) g_t^* + u_t$$

Um das unbeobachtbare  $g^*$  zu eliminieren, setzt man dafür Gleichung (14) ein. Damit entsteht ein partielles Anpassungsmodell, das nur beobachtbare Variablen  $x_j$  und ein Fehlerglied  $u$  enthält:

$$(16) \quad g_t = \lambda g_{t-1} + (1-\lambda) \left[ a_0 + \sum_{r=0}^q \sum_{j=1}^k a_{jr} x_{j,t-r} \right] + u_t$$

Setzt man für  $g_t$   $\bar{y}_t$  ein, dann wird deutlich, dass sich das partielle Anpassungsmodell vom kausalen Modell für gleitende Mittel (12) nur durch Berücksichtigung einer verzögerten abhängigen Variable ( $\bar{y}_{t-1}$ ) auf der rechten Seite der Gleichung unterscheidet. Diese Variable sorgt dafür, dass eine exogene Variable ( $x_{jt}$ ) ihren Einfluss  $a_{j0}$  in der aktuellen Periode ( $t, r=0$ ) nur zum Teil  $(1-\lambda)$  entfaltet;  $r$  Perioden später kumuliert sich dieser Einfluss zum Teil  $(1-\lambda)\lambda^r$ . Der Einfluss der verzögerten Variablen  $x_{j,t-r}$  nimmt also in geometrischer Reihe ab, ohne sich jemals zu verlieren; ihr gesamter Einfluss auf  $g_t$  wird erst nach unendlich vielen Perioden wirksam, die Hälfte ihres Einflusses nach  $\lambda/(1-\lambda)$  Perioden. Bei der Schätzung der Parameter von Gleichung (16) geben die Regressionskoeffizienten  $c_{jr}$  der Variablen  $x_{j,t-r}$  nur deren unmittelbare (in der Periode  $t$  eintretende) Wirkung an:  $c_{jr} = (1-\lambda)a_{jr}$ .

Eine Erweiterung des Modells (16) ist in zweifacher Hinsicht möglich. Erstens ist möglich, dass der angestrebte Zustand bereits durch weiter zurückliegende exogene Variablen bestimmt wird und die partielle Anpassung daher nicht in der unmittelbar folgenden Periode, sondern erst später beginnt. Lässt man alle derartigen Möglichkeiten zu, dann erhält man ein sehr flexibles partielles Anpassungsmodell mit sehr vielen unbekannten Parametern  $\lambda_l$  und  $a_{jr}$ :

$$(17) \quad g_t = \sum_{l=1}^p \lambda_l g_{t-l} + \left( 1 - \sum_{l=1}^p \lambda_l \right) \left[ a_0 + \sum_{r=0}^q \sum_{j=1}^k a_{jr} x_{j,t-r} \right] + u_t$$

$$\text{mit} \quad 0 \leq \sum_{l=1}^p \lambda_l < 1$$

Die Formel (17) erlaubt einerseits die Darstellung von verspätet einsetzenden Reaktionen auf die Änderung von exogenen Variablen, z.B. den Fall, dass positive Rahmenbedingungen herrschen, die die Erzeuger veranlassen, ältere Kühe nochmals besamen zu lassen - eine Reaktion, die sich auf die Milchlieferung erst viele Monate später auswirkt (ORTNER 1984). Andererseits kann damit z. B. auch dargestellt werden, dass der Entschluss, die Produktion anzupassen, erst nach einem Vergleich mit der Situation im Vorjahr getroffen wird. Die Hereinnahme verzögerter abhängiger Variablen ( $g_{t-l}$ ) kann auch dazu beitragen, dass man eine Fehlerkomponente  $u_t$  erhält, die nicht autokorreliert ist.

Und schließlich kann man (17) in (1) einsetzen, um ein umfassendes Modell für die ursprüngliche endogene Variable  $y_t$  zu erhalten:

$$(18) \quad y_t = s_{it} + \sum_{l=1}^p \lambda_l g_{t-l} + \left( 1 - \sum_{l=1}^p \lambda_l \right) \left[ a_0 + \sum_{r=0}^q \sum_{j=1}^k a_{jr} x_{j,t-r} \right] + w_t$$

mit  $w_t$  einer um Null verteilten Fehlervariable

Dieses Modell ist eine Erweiterung des kausalen Modells (13) und unterscheidet sich von diesem durch die gleitenden Durchschnitte  $g_{t-1}$ , die für eine partielle Anpassung von  $y$  an geänderte  $x_j$  sorgen. Durch die Zusammenfassung von (17) und (1) entsteht eine neue Fehlervariable  $w_t$ , die auch dann autokorreliert sein kann, wenn jene der Gleichung (17) nicht autokorreliert sein sollte.

Das partielle Anpassungsmodell (18) birgt das kausale Modell (13) in sich; dieses entsteht, wenn alle  $\lambda_1$  Null sind. Das Saisonbereinigungsmodell (4) ist in (18) nicht ganz enthalten: Nur wenn alle  $\lambda_1 = 0$  sind und das Glied in der eckigen Klammer mit  $\bar{y}$  übereinstimmt, erhält man mit (18) die Saisonfigur und die Fehlerkomponente des Saisonbereinigungsmodells.

Wenn wir für die glatten Komponenten in (18) den Ausdruck aus Gleichung (10) einsetzen und die resultierenden Modellparameter zu neuen Konstanten  $a_0$ ,  $b_{j1}$  und  $c_{jr}$  zusammenfassen, entsteht das partielle Anpassungsmodell in exogenen Variablen:

$$(19) \quad y_t = s_t + a_0 + \sum_{l=1}^p \sum_{j=1}^k b_{jl} \bar{x}_{j,t-l} + \sum_{r=0}^q \sum_{j=1}^k c_{jr} x_{j,t-r} + u_t$$

Man beachte, dass es nur verzögerte gleitende Mittel der exogenen Variablen enthält.

## 2.5. Die Fehlerkomponente

Die Fehlerkomponente repräsentiert in den bisher beschriebenen Modellen das Zufallselement, dessen Erwartungswert Null ist. Je geringer die Varianz dieser Komponente ist, desto größer ist die Varianz der übrigen Glieder auf der rechten Seite der Gleichung: Die Summe dieser Varianzen muss ja gleich sein der Varianz der endogenen Variable  $y$ . Der Versuch, die Varianz der Fehlerkomponente zu minimieren und derart die (durch den Einfluss exogener Variablen) erklärte Varianz zu maximieren, ist daher verständlich.

Die Annahme, dass die Fehlerkomponente normal verteilt mit konstanter Varianz ist, erscheint angesichts der Tatsache, dass die glatte Komponente der Milchlieferung wegen der Vorgabe von Richtmengen keinem steigenden oder sinkenden Trend folgt, plausibel. Die berechtigtere Frage ist vielmehr, ob die Fehlerkomponente seriell unabhängig ist; wenn sie es ist, erlaubt eine positive oder negative Ausprägung von  $u_t$  keine Aussage über die Höhe des Erwartungswertes von  $u_{t+1}$ . Wenn sie dagegen seriell korreliert ist, d.h. also, wenn eine über dem erwarteten Wert liegende Milchlieferung in einem Monat erwarten lässt, dass sie auch in einem der folgenden Monate über dem erwarteten Wert liegen wird, dann gehorcht die Fehlerkomponente einem autoregressiven Schema. Wie stark dieses ausgeprägt ist, hängt davon ab, wie Erwartungen gebildet werden und wie weit die im Modell verwendeten exogenen Variablen diese Erwartungen erklären können.

Am wahrscheinlichsten ist eine serielle Abhängigkeit der Fehlervariablen im Saisonbereinigungsmodell (4), denn dieses erwartet als glatte Komponente das gleitende Mittel der Milchlieferungen der vergangenen zwölf Monate. Wenn diese Erwartung nicht zutrifft und die Milchlieferung aus irgendeinem Grund (z.B. wegen einer Senkung der Richtmengen) ab diesem Zeitpunkt  $t$  auf Dauer um eine bestimmte Menge sinkt, ändert sich die Fehlerkomponente um einen dieser Senkung entsprechenden<sup>5</sup> (negativen) Wert. Um dies zu sehen, nehmen wir an, die Fehlerkomponenten und saisonalen Abweichungen sind Null – das Modell prognostiziert bis zum Eintritt dieser Senkung genau. Eine Senkung von  $y_{t-1}$  zu  $y_t$  ändert das gleitende Mittel bis

<sup>5</sup> bei Monatsdaten um einen 11/12 dieser Senkung großen Wert

zum Monat  $t$  um  $1/12$  dieser Senkung; daher entfallen  $11/12$  der angenommenen Senkung auf die Fehlerkomponente im Monat  $t$  ( $u_t$ ); da in den folgenden Monaten das gleitende Mittel monatlich um  $1/12$  der Senkung sinkt, steigt die Fehlerkomponente um denselben Betrag, um im Monat  $t+11$  wieder den Wert Null zu erreichen.

Dieses Beispiel zeigt, dass eine positive serielle Abhängigkeit der Fehlerkomponente mit großer Wahrscheinlichkeit erwartet werden kann. Die einfachste Annahme ist, dass die Fehlerkomponente  $u$  einem autoregressiven Prozess erster Ordnung folgt:

$$(20) \quad u_t = \rho u_{t-1} + \varepsilon_t$$

$$\text{mit } 0 < |\rho| < 1$$

und  $\varepsilon_t$  eine Zufallsvariable mit dem Erwartungswert Null und einer Kovarianz zwischen  $\varepsilon_t$  und  $\varepsilon_{t+j}$  ( $j = 1, 2, \dots$ ) von Null (seriell unabhängig)

Ein solcher Prozess kann auch in Form eines Lag-Polynoms dargestellt werden (s. z.B. ASSENMACHER 1995):

$$(21) \quad \varepsilon_t = u_t - \rho u_{t-1} = \alpha(L)u_t$$

$$\text{oder} \quad u_t = \frac{\varepsilon_t}{\alpha(L)}$$

Unter Anwendung von Lag-Polynomen auch für die exogenen Variablen in Gleichung (19) erhält man die exogen bzw. endogen dynamische Regressionsgleichung:

$$(22) \quad \alpha(L)y_t = \alpha(L)s_{it} + \alpha(L)a_0 + \alpha(L)\beta(L)\bar{x}_j + \alpha(L)\gamma(L)x_{j,t-l} + \varepsilon_t$$

Die Eigenschaften der Fehlervariable  $u_t$  sind ein Kriterium für die Brauchbarkeit eines Modells. Je kleiner die Varianz der  $u_t$  und je kleiner ihre serielle Abhängigkeit voneinander, desto leichter können die Parameter des Modells geschätzt werden und desto genauer können die Prognosen der endogenen Variable mit Hilfe des Modells sein. Gerade für das vorliegende Problem ist nicht nur jeder einzelne Fehler von Interesse, sondern auch die gleitende Summe dieser Fehler; diese spielt eine Rolle, wenn eine Prognose für mehrere Monate im Voraus erstellt werden muss, z.B. bis zum Ende eines Quotenjahres. Daher gilt es, die Varianz der Summe einzelner Prognosefehler zu minimieren; diese setzt sich zusammen aus der Summe der Varianzen und Kovarianzen aufeinander folgender Fehler:

$$(23) \quad \text{var}\left(\sum_{t=T+1}^T u_t\right) = \sum_{t=T+1}^T E(u_t^2) + 2 \sum_{t=T+1}^T \sum_{l=1}^{T-t} E(u_t u_{t+l})$$

Diese Varianz ist klein, wenn die Fehler nicht miteinander korreliert sind, sodass die Kovarianzen entfallen; sie wächst bei Autokorrelation der Fehler überproportional mit der Zahl der Summanden. Folgen die Fehler z.B. einem autoregressiven Prozess erster Ordnung wie in (20), dann errechnet sich die Varianz der Summe aus folgenden (mit dem Faktor  $\rho$  zunehmenden) Gliedern<sup>6</sup>:

$$(24) \quad E(u_t^2) = \sigma_u^2 = \frac{\sigma_\varepsilon^2}{1 - \rho^2}$$

$$(25) \quad E(u_t u_{t-l}) = \rho^l \sigma_u^2$$

<sup>6</sup> s. JOHNSTON(1984), S. 290

Die Autokorrelation der Fehler sollte daher bei Prognosemodellen möglichst gering sein. Wenn sie existiert, bedeutet dies, dass wirksame exogene Variablen im Modell vernachlässigt wurden, sodass sie durch den systematischen Teil der Fehlervariablen ( $\rho u_{t-1}$ ) ersetzt werden müssen.

## 2.6. Genauigkeit der Prognosen

Zur Beurteilung der Genauigkeit einer Prognose dient die Standardabweichung des Prognosefehlers. Die Varianz des Prognosefehlers hängt davon ab, wie weit die in der Prognoseperiode  $\tau$  wirkenden exogenen Variablen  $x_\tau$  von ihren Mittelwerten in der Referenzperiode entfernt sind:

$$\text{Var}(u_\tau) = \sigma_u^2 [1 + x_\tau' (X'X)^{-1} x_\tau]$$

$$\sigma_u^2 (X'X)^{-1} = \text{Var}(b)$$

mit

$b$  Vektor mit den geschätzten Regressionskoeffizienten

Für Modelle, deren Fehlervariablen einem autoregressiven Prozess erster Ordnung wie in (20) folgen, gilt analog dazu unter der Voraussetzung, dass  $\rho$  bekannt ist (GREENE 1993, S. 437):

$$(26) \quad \text{Var}(u_\tau) = \sigma_u^2 [1 + (x_\tau - \rho x_{\tau-1})' (X'X)^{-1} (x_\tau - \rho x_{\tau-1})] = \sigma_u^2 f_0$$

Prognosen in die Zukunft, die mit Hilfe von Modellen mit autokorrelierten Fehlern erstellt werden, hängen vom zuletzt beobachteten Fehler  $u_T$  ab (JOHNSTON 1984, S. 330):

$$(27) \quad \hat{y}_{T+n} = a + b x_{T+n} + \rho^n \hat{u}_T$$

Obwohl die gleichen exogenen Variablen zur Prognose verwendet werden, gibt es daher unterschiedliche Prognosewerte für die Periode  $T+n$  in Abhängigkeit davon, zu welchem Zeitpunkt die Prognose erstellt wird bzw. für welche Periode die Fehlervariablen  $u_T$  bekannt ist. Der Unterschied zwischen diesen Prognosewerten ist umso größer, je größer die Autokorrelation der Fehler  $\rho$  und je kleiner der Prognosehorizont  $n$  ist. Die Abweichung zwischen dem letzten Beobachtungswert und dem vom Modell dafür geschätzten Wert ( $u_T$ ) enthält das zufällige Element ( $\varepsilon_T$ ), dessen letzte beobachtete Ausprägung die Prognosen für die Zukunft systematisch verfälscht. Die Varianz des Fehlers der Prognosegleichung (27) ist geringer als die Varianz von  $u_t$  in Gleichung (20), denn diese zerfällt in zwei Teile:

$$\text{Var}(u_t) = \text{Var}(\rho u_{t-1}) + \text{Var}(\varepsilon_t)$$

Der erste dieser Teile verschwindet, sobald  $u_{t-1}$  bekannt ist und in die Prognosegleichung (20) aufgenommen werden kann. Ähnliches gilt für Gleichung (27), deren Fehler ebenfalls ein Teil der Varianz von  $u_t$  ist; diese Varianz zerfällt in:

$$\text{Var}(u_t) = \text{Var}(\rho^n u_{t-n}) + \text{Var}\left(\sum_{k=0}^{n-1} \rho^k \varepsilon_{t-k}\right) = \rho^{2n} \sigma_u^2 + (1 - \rho^{2n}) \sigma_\varepsilon^2$$

Der zweite Teil ist die bedingte Varianz von  $u_t$  bei gegebenem  $u_{t-n}$  (sie hängt nicht von  $t$ , sondern nur von  $n$  ab). Die Varianz des Prognosewertes (27) für die Periode  $T+n$  ( $n$  Perioden in die Zukunft) bei gegebenem  $u_T$  ist daher (unter Verwendung von 24)

$$(28) \quad \text{Var}(y_{T+n} | x_{T+n}, u_T) = (1 - \rho^{2n}) \sigma_u^2 = \frac{(1 - \rho^{2n})}{(1 - \rho^2)} \sigma_\varepsilon^2$$

Die Varianz des Prognosewertes für die nächstfolgende Periode entspricht erwartungsgemäß der Varianz des Restfehlers  $\sigma_\varepsilon^2$ . Die Varianz der Summe einzelner Prognosewerte ergibt sich auf Grund von (24) und (25) aus der Vor- und Nachmultiplikation einer entsprechend dimension-

nierten Matrix mit einem Vektor, dessen Elemente die Wurzel aus (28) enthalten, und der Multiplikation des Ergebnisses mit dem Faktor  $f_0$  aus (26), der von den beobachteten exogenen Variablen abhängt:

$$(29) \quad \text{Var}\left(\sum_{k=1}^n \hat{y}_{T+k}\right) = f_0 \begin{bmatrix} f_1 & f_2 & f_* & f_n \end{bmatrix} \begin{bmatrix} 1 & \rho & \rho^* & \rho^{n-1} \\ \rho & 1 & \rho & \rho^* \\ \rho^* & \rho & 1 & \rho \\ \rho^{n-1} & \rho^* & \rho & 1 \end{bmatrix} \begin{bmatrix} f_1 \\ f_2 \\ f_* \\ f_n \end{bmatrix}$$

mit  $f_k = \sigma_\varepsilon \sqrt{\frac{(1-\rho^{2k})}{(1-\rho^2)}}$

Bei der Berechnung dieser Varianzen müssen  $\sigma$  und  $\rho$  durch ihre Schätzwerte ersetzt werden; im Fall von  $\rho$  bedingt dies eine zusätzliche Unsicherheit, die im beschriebenen Schätzwert nicht berücksichtigt ist.

Die Berechnung der Varianz der Summe von Prognosen über mehrere Perioden ist mit Gleichung (29) möglich. Daneben interessiert aber auch die Treffsicherheit konkreter Prognosen für bestimmte Perioden, die auch in der Zukunft liegen können, um die Leistung bestimmter Prognosemodelle und -methoden vergleichen zu können. Dabei muss eine Beurteilung auch für den Fall möglich sein, dass bestimmte Statistiken der Prognosemodelle, z.B.  $\sigma$ ,  $\rho$  und  $f_0$ , unbekannt sind. Zur Beurteilung der Treffsicherheit von Prognosen dienen der durchschnittliche absolute Prognosefehler ( $z_1$ , MAPE, mean absolute prediction error) und die so genannte Zuverlässigkeit von Prognosen, definiert als die Standardabweichung der Prognosefehler ( $z_2$ , RMSE, root mean squared error):

$$(30) \quad z_1 = \frac{1}{n} \sum_{k=T+1}^{T+n} |y_k - \hat{y}_k|$$

$$(31) \quad z_2 = \sqrt{\frac{1}{n} \sum_{k=T+1}^{T+n} (y_k - \hat{y}_k)^2}$$

## 2.6. Andere Modelle

Da auch andere als die bisher vorgestellten Modelle zur Prognose der Milchlieferung in Österreich verwendet wurden, sollen sie vollständigshalber erwähnt werden. ORTNER (1984) entwickelte ein partielles Anpassungsmodell ähnlich jenem, das mit Gleichung (18) beschrieben wird, allerdings mit  $y_{t-1}$  an Stelle von  $g_{t-1}$  (bei  $\rho = 1$ ).  $y_{t-1}$  folgt aber - wie  $y_t$  - einer Saisonfigur, sodass ein Teil der Saisonfigur, die eigentlich mit  $s_t$  dargestellt werden sollte, durch  $y_{t-1}$  erklärt wird. Die saisonale Verteilung der Milchlieferung wird daher mit diesem Modell nicht direkt geschätzt. Diese Studie liefert allerdings einen wesentlichen Beitrag zur Theorie, der hier zitiert werden kann:

„Darüber, wie viel Milch angeliefert wird, entscheiden die Bauern teils unmittelbar, indem sie mehr oder weniger Milch verfüttern, größtenteils aber lange vor dem Zeitpunkt der Anlieferung, nämlich dann, wenn sie sich entschließen, ihre Produktion aufrechtzuerhalten, auszudehnen oder einzuschränken. Ein kritischer Zeitpunkt für die Einschränkung der Produktion ist gegeben, wenn eine Kuh zur Besamung ansteht. Wird sie erfolgreich besamt, dann wird 287 Tage später ein Kalb geboren und die Milchproduktion geht weiter. Andernfalls liefert sie (bei einer Zwischenkalbezeit von 416 Tagen - siehe FESL 1980, S. 63 - und



einer Laktationszeit von 305 Tagen) noch 176 Tage (oder ca. 6 Monate) lang Milch und wird dann geschlachtet.

Kritisch für die Ausdehnung der Milchproduktion ist ferner jener Zeitpunkt, zu dem über die Verwendung eines weiblichen Kalbes entschieden wird, also drei bis vier Monate nach seiner Geburt. Entschließt sich ein Bauer zur Aufzucht, dann kann dieses Kalb frühestens 22 Monate später selbst Milch produzieren; bei einem Erstkalbealter von 30 Monaten, das dem Landesdurchschnitt vermutlich eher entspricht, dauert es dagegen 27 bis 28 Monate bis zum Einsetzen der Milchproduktion.

Ein weiterer kritischer Zeitpunkt ist jener, zu dem das Jungrind besamt wird. Hier entscheidet sich, ob es weiter aufgezogen werden soll, um den Milchkuhbestand zu ergänzen, oder ob es als Schlachtvieh verkauft werden soll. Bei gelungener Deckung dauert es 9 bis 10 Monate bis zum Beginn der Laktation. Ähnlich wichtig ist der Zeitpunkt der Deckung einer schon länger genutzten Kuh, bei der Fruchtbarkeitsprobleme auftreten. Der Bauer würde hier entscheiden, ob dies die letzte Trächtigkeit der Kuh sein soll. Mit 9 Monaten bis zum letzten Laktationsbeginn und 10 Monaten Laktation ergibt sich eine Auswirkung dieser Entscheidung auf die Milchanlieferung nach 19 Monaten.

Zusammenfassend gehen wir also von der Hypothese aus, daß die Entscheidungen der Bauern über eine Änderung der Milchanlieferung im Monat der Änderung sowie 6, 9, 19 und 27 Monate vorher getroffen werden. Die nächste Frage ist, nach welchen Informationen der Bauer seine Entscheidungen trifft. Es sind dies zweifellos die - erwarteten - Preise seiner Produkte und jene der Produktionsmittel, insbesondere des Futters. Letzteres ist im Fall der Rinderhaltung vorwiegend wirtschaftseigenes Futter ohne Marktpreis, sodaß auch die Verfügbarkeit von Futter aus der letztjährigen Ernte eine Rolle spielt.“

WÖRGÖTTER(1990) entwickelte ein vektorautoregressives Modell zur Prognose der monatlichen Milchanlieferung<sup>7</sup>. Im Idealfall werden dabei die endogenen Variablen durch die eigenen verzögerten Werte sowie durch aktuelle und verzögerte exogene Variablen erklärt. Da diese Konstruktion eine Unmenge von Parametern mit sich bringt, müssen Wege gesucht werden, diese zu reduzieren. Einer davon ist, zuerst jede einzelne Variable in eine autoregressive und eine Fehlerkomponente zu zerlegen und anschließend die Fehler dieser Prozesse zueinander in Beziehung zu setzen: Frühere Fehler (Innovationen) der exogenen Variablen erklären die Fehler der abhängigen Variable, und deren Fehler erklären - soweit möglich - die Fehler der exogenen Variablen. Diese Vorgehensweise lässt noch immer sehr viel Gestaltungsspielraum. Ihr Ergebnis eignet sich nach meinen Erfahrungen mit den Prognoseeigenschaften des WÖRGÖTTER-Modells eher für analytische denn für Prognosezwecke, weil Modelle entstehen können, deren Prognosefehler in die Zukunft sich sehr schnell vergrößern.

---

<sup>7</sup> Dieses Modell wurde im Auftrag des BMLF entwickelt und der Bundesanstalt für Agrarwirtschaft zur Verfügung gestellt.

### 3. Schätzung der Modellparameter

Zweifelloos repräsentiert Gleichung (19) in Verbindung mit Gleichung (20) das umfassendste hier vorgestellte Modell. Es enthält die meisten Parameter, und es enthält mehr oder weniger alle bereits besprochenen Modelle, die durch Eliminierung bestimmter Glieder (Nullsetzen bestimmter Parameter) aus Gleichung (19) gewonnen werden können. Eine solche Vereinfachung ist aus schätztechnischen Gründen notwendig, weil auf jeden zu schätzenden Parameter zumindest drei Beobachtungen entfallen müssen, um ein statistisch sinnvolles Ergebnis zu erhalten. Bei Monatsdaten bedeutet das, dass zur ökonometrischen Schätzung einer konstanten Saisonfigur (zwölf Parameter  $s_{10}$  in Gleichung 6) mindestens vier Beobachtungsjahre vorliegen müssen, denn eines wird zur Berechnung des gleitenden Durchschnitts benötigt. Zur Berechnung einer variablen Saisonfigur (mit weiteren zwölf  $s_{11}$ ) braucht man bereits sieben Beobachtungsjahre. Dies erklärt, warum eine konventionelle Saisonbereinigung entsprechend den Gleichungen (1) bis (6) so gerne umfassenderen Modellen vorgezogen wird.

#### 3.1. Das Saisonbereinigungsmodell

Betrachten wir zuerst, wie sich die Saisonbereinigung im Vergleich zu Gleichung (19) darstellt. Unter Verwendung von (4) für die gleitenden Durchschnitte in Gleichung (1) und unter Verwendung fixer saisonaler Effekte ( $s_i$ ) haben wir:

$$(32) \quad y_t = g_t^y + s_i + u_t$$

Auf der rechten Seite von (32) kommt - im Gegensatz zu Gleichung (18) - nicht der verzögerte, sondern der aktuelle gleitende Durchschnitt ( $g_t$ ) vor; er enthält einen Teil von  $y_t$  und ist daher nicht unabhängig von  $u_t$  - mit der Folge, dass eine Schätzung der Koeffizienten von Gleichung (32) (der  $s_i$ ) mittels Regression verzerrte Ergebnisse liefern würde. Durch entsprechende Umformungen kann dieses Problem behoben werden:

$$(33) \quad y_t = \sum_{l=0}^{m-1} b y_{t-l} + s_i + u_t = b y_t + \sum_{l=1}^m b y_{t-l} - b y_{t-m} + s_i + u_t$$

$$y_t(1-b) = \bar{y}_{t-1} - b y_{t-m} + s_i + u_t$$

Das erste Glied auf der rechten Seite dieser Gleichung ist das verzögerte gleitende Mittel von  $y$ . Zum Zeitpunkt  $t$  ist auch das zweite Glied (wegen  $b=1/m$ ) bekannt; wir bringen diese beiden Glieder auf die linke Seite der Gleichung und erhalten so die Regressionsgleichung:

$$(34) \quad y_t(1-b) + b y_{t-m} - \bar{y}_{t-1} = s_i + u_t$$

multiplizieren beide Seiten der Gleichung mit  $(1-b)$  zur Schätzung der für Gleichung (32) gültigen Saisonfigur:

$$(35) \quad y_t(1-b) + b y_{t-m} - \bar{y}_{t-1} = \sum_{i=1}^m s_i D_{it} + u_t$$

$$\text{mit } (1-b) = (m-1)/m$$

$$m = \text{Zahl der Perioden pro Jahr}$$

$$D_{it} = 1 \text{ oder } 0$$

In (35) wurde die (hier als konstant angenommene) Saisonfigur erstmals vollständig (in Form einer linearen Kombination von Dummy-Variablen) angeschrieben: Der saisonale Effekt des Monats  $i$  ist nur dann ungleich Null, wenn  $t$  den Monat  $i$  bezeichnet; in diesem Fall nimmt die



Dummy-Variable  $Di_t$  des Monats  $i$  den Wert eins, sonst den Wert Null an. Analog dazu ist die Regressionsgleichung zur Schätzung eines Saisonbereinigungsmodells mit Saisonkoeffizienten, die einem Trend folgen:

$$(36) \quad y_t(1-b) + b y_{t-m} - \bar{y}_{t-1} = \sum_{i=1}^m s_{i0} Di_t + \sum_{i=1}^m s_{i1} DTi_t + u_t$$

mit

$DTi_t$  eine Trenddummyvariable

Gleichung (6) zeigt, wie die variable Saisonfigur  $s_{it}$  aus den Koeffizienten von (29) berechnet wird. Bei der Saisonfigur  $s_{it}$  handelt es sich um absolute oder relative Abweichungen vom gleitenden Mittel, je nachdem, ob die Variable  $y$  und sein gleitendes Mittel absolut oder in Logarithmen gemessen werden:

### 3.2. Kausale Modelle

Ein kausales Modell (13) entsteht aus (19), wenn

$$\begin{aligned} \lambda_1 &= 0 && \text{für alle } l \\ b_{ij} &= 0 && \text{für alle } i \text{ und } j \end{aligned}$$

Das Modell (13) schließt daher die Möglichkeit einer partiellen Anpassung der Milchanlieferung an geänderte Rahmenbedingungen in dem Maß aus, in dem die verwendeten exogenen Variablen nicht geglättet sind. Bei  $k$  Variablen, die  $y$  möglicherweise beeinflussen, gibt es  $q \cdot k$  Parameter ( $a_{j1}$ ), die ungleich Null sein können.  $q$  gibt an, über wie viele Perioden die Änderung einer exogenen Variable die abhängige Variable  $y$  beeinflusst; das können im Fall der Milchanlieferung bis zu 36 (Monate) sein. Da die statistische Schätzung so vieler Parameter in der Praxis unmöglich ist, müssen Vorentscheidungen über die zu berücksichtigenden Verzögerungen (nicht alle 36) und die als wirksam erachteten ( $k$ ) Variablen getroffen werden.

Eine Möglichkeit, die Zahl der Modellparameter um den Faktor  $m$  zu verringern, ist die in Gleichung (10) getroffene Annahme, dass die Wirkungen der exogenen Variablen einheitlich ein Jahr lang anhalten und sich gleichmäßig über dieses Jahr verteilen. Um statistisch festzustellen, ob bis zum Wirksamwerden der Änderung einer exogenen Variable einige Perioden verstreichen, kann man die Kreuzkorrelationen zwischen  $\bar{y}_t$  und  $\bar{x}_{t-r}$  ermitteln und dann nur jene Verzögerungen von exogenen Variablen berücksichtigen, die hohe und mit dem erwarteten Vorzeichen versehene Korrelationen mit  $\bar{y}_t$  aufweisen. Im Fall, dass als exogene Variable im Modell nur deren gleitende Durchschnitte berücksichtigt werden, werden kurzfristig wirkende Einflüsse der Fehlervariable zugeschrieben, sodass diese wahrscheinlich autokorreliert sein wird.

Verwendet man eine solche Modellformulierung nicht für  $y$ , sondern für dessen gleitenden Durchschnitt, dann stellt sich dieses Problem nicht:

$$(37) \quad \bar{y}_t = \bar{a}_0 + \sum_{r=0}^p \sum_{j=1}^k \bar{a}_{j,t-r} \bar{x}_{j,t-r} + u_t$$

Vielmehr bietet sich eine Funktion wie die auf der rechten Seite der Gleichung (37) dafür an, an Stelle der glatten Komponenten in Gleichung (18),  $\sum \lambda_1 g_{t-1}$  eingesetzt zu werden. In diesem Fall verschwinden die  $\lambda_1$ -Glieder in (18), die gleitende Durchschnitte von  $y$  repräsentieren, zu Gunsten einer Funktion von gleitenden Durchschnitten der  $x_j$ . Es entsteht ein neues kausales Modell, das den Vorteil des partiellen Anpassungsmodells inkorporiert, aber eine andere Fehlervariable als dieses hat; seine Eigenschaften werden anhand dieser Fehlervariable zu beurteilen sein.

## 4. Vorgehensweise

### 4.1. Konventionelle Ermittlung der Saisonfigur

Normalerweise werden saisonale Abweichungen ( $sa_t$  in Gleichung 3) vom zentrierten gleitenden Durchschnitt einer Zeitreihe berechnet. Da die saisonalen Abweichungen die Fehlerkomponente  $u_t$  enthalten, muss man diese abziehen, um die Saisonfigur  $s_t$  zu isolieren. Von der Fehlerkomponente ist aber gemäß Annahme nur bekannt, dass ihr Mittelwert Null ist und dass sie eine konstante Varianz hat. Bei einer hier als „konventionell“ bezeichneten Ermittlung der Saisonfigur wird nur die erste dieser beiden Annahmen genutzt: Der Mittelwert der saisonalen Abweichungen in mehreren Jahren enthält den Mittelwert der entsprechenden Ausprägungen der Fehlervariable  $u_t$ . Unter der Annahme, dass dieser Null ist, erhält man durchschnittliche saisonale Abweichungen, die als Saisonfigur bezeichnet werden. Sie unterscheiden sich von dieser durch den Mittelwert der entsprechenden  $u_t$ :

$$\overline{sa}_i = \overline{s}_i + \overline{u}_i$$

Diese Diskrepanz zwischen dem Durchschnitt der saisonalen Abweichungen und der Saisonfigur wird vernachlässigt; sie ist größer, wenn nur wenige Beobachtungen zur Berechnung des Mittelwertes von  $sa_t$  verwendet werden. Andererseits kann man anhand der gleitenden Mittelwerte von saisonalen Abweichungen ermitteln, wie sich diese im Lauf der Zeit verändern und ob sie eventuell einem Trend folgen. Das Ergebnis mit Mittelwerten aus jeweils drei Jahren wird im Anhang A5 gezeigt. Demnach weichen die monatlichen Abweichungen im Durchschnitt von jeweils drei Jahren um bis zu 5 % von ihrem langjährigen Durchschnitt ab. Ein eindeutiger Trend einzelner monatlicher Abweichungen ist nicht erkennbar. Die große Variabilität der durchschnittlichen saisonalen Abweichungen bedeutet jedenfalls, dass der dreijährige Durchschnitt von  $u_t$  bei weitem nicht Null ist und dass beträchtliche Fehler möglich sind, wenn sie zur Prognose der Saisonfigur und der Milchlieferung verwendet werden.

### 4.2. Ermittlung des Saisonbereinigungsmodells

Um die Saisonfigur der Milchlieferung schätzen zu können, braucht man eine ausreichende Zahl von Beobachtungen der saisonalen Lieferungen sowie der Daten jener exogenen Variablen, die die Saisonfigur verzerren könnten; dies gilt nicht nur für das Saisonbereinigungsmodell, das in Gleichung (25) gegeben ist. Die dort spezifizierte Saisonfigur besteht aus den Summanden  $s_t$ , die über den gesamten Beobachtungszeitraum gleich bleiben. Diese sehr allgemeine Formulierung kann flexibilisiert werden, indem man die Möglichkeit vorsieht, dass die saisonalen Abweichungen von der glatten Komponente einem Trend folgen, also im Lauf der Zeit (relativ) kleiner oder größer werden.

Außerdem ist anzunehmen, dass der Umfang der Lieferungen in den beiden letzten Monaten eines Quotenjahres auch davon abhängt, inwieweit bis dahin die Einzelrichtmengen oder nationalen Gesamtrichtmengen bereits erfüllt sind. Dieser Umstand kann, wenn er den Lieferanten bekannt ist, die saisonalen Abweichungen in diesen Monaten beeinflussen.

Um diesen Einfluss im Modell geltend zu machen, wurde das Verhältnis zwischen den Lieferungen bis April und bis Mai<sup>8</sup> eines jeden Quotenjahres zu den für dieses Quotenjahr vergeb-

<sup>8</sup> Nach dem EU-Beitritt statt dessen Jänner bzw. Feber

nen Einzelrichtmengen (abzüglich der Mengen, die für den freiwilligen Lieferverzicht angemeldet waren) berechnet; ein hohes Verhältnis bedeutet, dass die Lieferanten bis dahin schon viel geliefert haben und daher geneigt sind, im vorletzten und letzten Monat des Quotenjahres nur mehr wenig zu liefern, um der Bezahlung eines zusätzlichen Absatzförderungsbeitrages bzw. einer Superabgabe zu entgehen. Die Abweichungen dieser Verhältniszahlen von ihren Durchschnitten in der Referenzperiode<sup>9</sup> sind ein Maß für die relative Über- (oder Unter-) lieferung der Milchrichtmenge; mit den so errechneten Überlieferungsvariablen kann ökonometrisch geprüft werden, ob sie für Abweichungen von der üblichen Saisonfigur im Mai und Juni (bzw. Feber und März) verantwortlich sind.

Aus Gleichung (29) ergibt sich somit folgendes Saisonbereinigungsmodell, dessen Parameter geschätzt werden sollen:

$$(38) \quad (y_t - g_{t-1}^s)(1-b) = \sum_{i=1}^m s_{0i} Di_t + \sum_{i=1}^m s_{1i} DTi_t + b_1 BA^+ + b_2 BA^- + b_3 BM^+ + b_4 BM^- + u_t$$

mit

$y_t$	Logarithmus der Milchanlieferung im Monat $t$
$g_{t-1}^s$	gleitendes Mittel von $y_t$ in den letzten elf Monaten
$b = 1/m$	(= 1/12 bei Monatsdaten)
$m$	Zahl der saisonalen Abweichungen
$s_{0i}, s_{1i}$	Koeffizienten der saisonalen Abweichung in Saison $i$
$Di_t$	Dummyvariable für den Monat $i$
$DTi_t$	Dummyvariable / Trendvariable für den Monat $i$
$b_j$	Koeffizient der Überlieferungsvariablen $j$
$BA^+$	positive Überlieferungen bis April
$BA^-$	negative Überlieferungen bis April
$BM^+$	positive Überlieferungen bis Mai
$BM^-$	negative Überlieferungen bis Mai
$u_t$	Fehlervariable mit (25)

Die Schätzung erfolgt zuerst mittels multipler Regression (OLS), wobei jene Überlieferungsvariablen, deren Koeffizienten ein falsches Vorzeichen haben, und jene Trendvariablen, die nicht zur Verkleinerung der geschätzten Varianz von  $u$  beitragen, aus dem Modell herausgenommen werden<sup>10</sup>. Anschließend werden Überlieferungsvariablen, die wenig zur Erklärung der Varianz leisten, verworfen; Saisondummys werden aus dem Modell nur dann eliminiert, wenn ihr T-Wert geringer als 0,3 ist. Abschließend werden die Parameter des so spezifizierten Modells genauer mittels Verallgemeinerter Kleinsten Quadrate (GLS) geschätzt, um eine unverzerrte Schätzung der Standardfehler der geschätzten Koeffizienten und der Fehlervariablen  $u_t$  zu erhalten, wenn diese autokorreliert sind (d.h., wenn  $\rho$  in Gleichung 20 nicht Null ist); dazu wurde die von Hildreth-Lu vorgeschlagene Grid-Search-Methode angewandt<sup>11</sup>. Die dabei erhaltenen T-Werte sind Kriterien für eine weitere Elimination von Variablen, die einen geringen Erklärungsbeitrag leisten.

<sup>9</sup> Die kumulierten Lieferungen betrugen im Durchschnitt von Juli bis April 82,378 % und von Juli bis Mai 91,767 % der vergebenen Einzelrichtmengen; eine Abweichung von diesen Werten wirkt gemäß Modellannahme im jeweils folgenden Monat (Mai, Juni). Die entsprechenden Werte bis Jänner bzw. Feber betrugen 82,964 und 90,354 % der nationalen Quote (A und D-Quote).

<sup>10</sup> Kriterium dafür ist ein t-Wert des Koeffizienten von  $< 1$ .

<sup>11</sup> Die ausschließliche Verwendung dieses Schätzverfahrens führte zum selben Endergebnis.

### 4.3. Ermittlung der kausalen Modelle

Kausale und partielle Anpassungsmodelle werden zur Lösung des anstehenden Problems - der Ermittlung saisonaler Abweichungen - nicht unbedingt benötigt. Sie bieten aber die Möglichkeit, die Saisonfigur genauer als mit dem Saisonbereinigungsmodell (29) oder (32) zu bestimmen, wenn die glatte Komponente anders als das gleitende Mittel verläuft. Ein Indikator, dass dies der Fall ist, sind autokorrelierte Fehler in (32). Entsprechend müssten kausale Modelle auch genauere Prognosen in die Zukunft ermöglichen.

Kausale Modelle und partielle Anpassungsmodelle enthalten neben den bereits erwähnten Überlieferungsvariablen weitere exogene Variablen, die auf die jeweilige saisonale Ausprägung der Milchlieferung Einfluss nehmen und eine verzerrte Schätzung der saisonalen Abweichungen verursachen können, wenn sie nicht berücksichtigt werden. Einige derartige Prognosemodelle wurden von der Bundesanstalt für Agrarwirtschaft im Rahmen des Projekts Nr. AW/73/86 entwickelt und in unregelmäßigen Abständen aktualisiert; sie wurden jedoch seit ORTNER (1984) nicht mehr dokumentiert. Da sie Auskunft über die Auswirkungen der wirtschaftlichen Rahmenbedingungen (Preise) und politischen Maßnahmen (Änderungen der Milchrichtmengen, Prämien für freiwillige Lieferverminderung und Rindfleischerzeugung) auf die Milchlieferung geben, stellen sie zusätzliche Informationen bereit, die früher oder später für Zwecke der Politikanalyse benötigt werden könnten. Eine derartige Analyse führte z.B. GALLETO (1995) über die freiwillige Lieferverzichtsaktion in Österreich durch, eine andere ORTNER (1987) über andere Möglichkeiten, Mittel einzusparen, die benötigt wurden, um den Absatz der angelieferten Milch sicherzustellen.

Die Ermittlung eines kausalen Modells (13) erfolgt ausgehend von Gleichung (8) unter Berücksichtigung einer trendabhängigen Saisonfigur und der Überlieferungsvariablen wie in Gleichung (29). Variablen, die keinen Beitrag zur Verringerung der geschätzten Varianz von  $u$  leisten, werden aus dem Modell genommen; dabei werden dieselben Kriterien wie beim Saisonbereinigungsmodell angewandt. Anschließend werden Kreuzkorrelationen zwischen den Fehlern des Modells ( $u$ ) und den in Frage kommenden verzögerten exogenen Variablen berechnet, um zu ermitteln, welche  $x_{j, t-1}$  einen Beitrag zu einer genaueren Prognose erwarten lassen; als Kriterium dafür dienen ein signifikanter Korrelationskoeffizient, ein plausibles Vorzeichen des betreffenden Regressionskoeffizienten und ein Standardfehler, der kleiner als der Absolutwert des geschätzten Koeffizienten ist; mit dieser Vorgehensweise kann das höchstmögliche justierte Bestimmtheitsmaß<sup>12</sup> erreicht werden. Sollte das resultierende Modell autokorrelierte Fehler aufweisen, dann wird dies durch eine abschließende Schätzung seiner Koeffizienten mittels Verallgemeinerter Kleinsten Quadrate nach dem Hildreth-Lu-Verfahren berücksichtigt, nach der dann weitere Variable aus dem Modell genommen werden können.

Die Ermittlung eines partiellen Anpassungsmodells (19) erfolgt entsprechend der Vorgangsweise für das kausale Modell in zwei Schritten: Zuerst wird unter Berücksichtigung einer trendabhängigen Saisonfigur und unverzögerten exogenen Variablen wie in Gleichung (8) ein Modell mit möglichst großer Übereinstimmung mit den Daten gesucht, dessen Koeffizienten richtige (theoretischen Annahmen entsprechende) Vorzeichen haben. Dieses Modell wird zuerst um verzögerte gleitende Durchschnitte von exogenen Variablen und dann um verzögerte exogene Variablen erweitert, bis die geschätzte Varianz des Fehlers möglichst klein ist. Die Suche nach den geeigneten exogenen Variablen erfolgt anhand von Kreuzkorrelationen zwischen der Fehlervariable des jeweils vorliegenden Modells und den aktuellen und verzögerten exogenen Va-

<sup>12</sup> D.h. der Anteil der durch das Modell erklärten Varianz an der Gesamtvarianz der abhängigen Variablen.

riablen; ins Modell aufgenommen werden jene exogenen Variablen, die die geschätzte Varianz der Fehlervariable reduzieren, wobei verzögerte gleitende Durchschnitte den nicht transformierten Variablen vorgezogen werden. Abschließend werden die Parameter des so ermittelten Modells, wenn eine Autokorrelation der Fehlervariablen vorliegt, mittels Verallgemeinerter Kleinsten Quadrate geschätzt und jene Variablen wieder entfernt, die wenig zur Verringerung der Varianz der Fehlervariable beitragen.

#### 4.4. Auswertung der Ergebnisse

Als Ergebnis erhalten wir drei Modelle mit unterschiedlichen Saisonfiguren und eine Saisonfigur, die mit der herkömmlichen Saisonbereinigungsmethode geschätzt wurde. Da die Prognose auf Basis einer Saisonfigur genauso erstellt wird wie die Prognose mit dem Saisonbereinigungsmodell<sup>13</sup>, genügt es, die Ergebnisse der drei ökonometrisch geschätzten Modelle zu vergleichen. Welches dieser drei Modelle das größte Vertrauen genießt, hängt nicht nur davon ab, wie gut das jeweilige Modell die Entwicklung in der Vergangenheit abbilden kann und wie klein die Fehler sind, die es dabei macht, sondern es kommt auch darauf an, welche Fehler die jeweiligen Modelle bei Prognosen in die Zukunft machen und welcher Aufwand und welche Annahmen für solche Prognosen nötig sind. Unter dem Grundsatz, je einfacher, desto besser, müssen wir die anhand der Gleichung (36) geschätzte Saisonfigur bevorzugen oder zumindest als jenen Standard verwenden, den ein anderes Modell überbieten muss, um seine eventuelle Verwendung zu rechtfertigen.

Sollte es gelingen, Erklärungsmodelle mit geringerer Varianz und einer geringen Autokorrelation der Fehler zu finden, so garantiert dies keineswegs deren Überlegenheit über andere Modelle. Da viele exogene Variablen als Ursache für kurzfristige Fluktuationen der glatten Komponente in Frage kommen, können viele statistische Modelle mit einer geringen Varianz der Fehler gebildet werden. Eine theoretisch begründete Entscheidung für eines davon lässt sich nicht mit Sicherheit treffen. Deshalb bleibt diese Entscheidung immer mehr oder weniger arbiträr, und es bleibt unklar, ob ein empirisch gefundenes Modell tatsächlich die Struktur des interessierenden Systems abbildet oder ob es nur zufällig mit dem System, das in der Referenzperiode herrschte, übereinstimmt.

Daher wird man zwar einerseits die statistischen Daten der Regressionsgleichungen beachten, andererseits aber auf die Genauigkeit der Prognosen der verschiedenen Modelle außerhalb der Referenzperiode ebenfalls einigen Wert legen. Das erfordert die Erstellung einer ausreichenden Anzahl solcher Prognosen unter realistischen Bedingungen und deren Vergleich mit den tatsächlichen Werten. Realistisch heißt, dass die dazu verwendeten Prognosemodelle monatlich aktualisiert werden sollten, um die jeweils aktuellsten Daten zu berücksichtigen, was infolge der fortgeschrittenen Computertechnik ohne bemerkenswerten Arbeitsaufwand erfolgen könnte. Aber mit Prognosemodellen, die in dieser Studie erst entwickelt werden, ist das noch nicht möglich. Hier kann man nur einige wenige Monate in die Zukunft prognostizieren, und zwar ohne Aktualisierung der Modelle. Ein Vergleich der Ergebnisse dieser Prognosen in die Zukunft wird daher kaum mehr aussagekräftig sein als ein Vergleich der Fehler von ex-post-Prognosen und deren Hochrechnungen auf ganze Jahre.

Dennoch werden hier auch Prognosen in die Zukunft erstellt und ausgewertet. Bei einem Vergleich der Ergebnisse des Saisonbereinigungsmodells mit jenen der anderen Modelle ist zu beachten, dass ersteres jene glatte Komponente (4) extrapoliert, die zuletzt beobachtet wurde;

---

<sup>13</sup> Dieses berücksichtigt allerdings auch die so genannten Überlieferungsvariablen, sofern sie relevant sind (s. Kapitel 4.2).



die Genauigkeit der Prognose mit diesem Modell hängt also davon ab, inwieweit die Annahme einer konstanten glatten Komponente für die Prognoseperiode zutrifft. Sicherlich werden die glatten Komponenten der Ausgangssituation und der Prognoseperiode desto näher liegen, je weniger Zeit zwischen diesen Perioden liegt, d.h., je kürzer der Prognosehorizont ist. Für näher an der Gegenwart liegende Perioden kann man daher genauere Prognosen erwarten. Bei den kausalen Modellen ist eine solche Erwartung nicht gerechtfertigt, weil sie die glatte Komponente in Abhängigkeit von exogenen Variablen prognostizieren; wenn diese bekannt sind, prognostizieren kausale Modelle immer die gleiche glatte Komponente. Diese ändert sich nur, wenn autokorrelierte Fehler vorliegen und in der Prognose berücksichtigt werden; durch diese Fehler sollte sich die Genauigkeit der Prognose in den ersten zwei bis drei Prognoseperioden verbessern. Das gilt aber auch für das Saisonbereinigungsmodell.

Die Zuverlässigkeit der Prognosen in die Zukunft wird mit folgender Formel (siehe auch 31) bestimmt:

$$Z_2^{n,M} = \sqrt{\frac{1}{6} \sum_{k=T+1}^{T+6} (y_k - \hat{y}_k^{n,M})^2}$$

Darin gibt  $n$  an, wie weit zurückliegende Daten zur Berechnung der Prognose verwendet werden bzw. wie weit der prognostizierte Wert in der Zukunft liegt.  $M$  bezeichnet das verwendete Prognosemodell, und  $T+1$  ist der Juli 1998. Die Ergebnisse werden in Abbildung 7 gezeigt. Eine analoge Formel (siehe auch 30) wurde für den absoluten Prognosefehler verwendet, der einen ähnlichen Verlauf zeigt. In Abbildung 6 wird daher der durchschnittliche Prognosefehler dargestellt.

Mit welcher Saisonfigur die Modelle rechnen, ist aus den Koeffizienten der Regressionsgleichungen nicht notwendigerweise ersichtlich. Wenn in den Erklärungsmodellen eine Konstante ( $a_0$ ) (und allenfalls eine Trendvariable) vorkommt, dürfen sie nur  $m-1$  Saison-Dummys und dazugehörige Koeffizienten enthalten, wobei letztere Abweichungen von der gewählten Referenzsaison repräsentieren; andernfalls enthalten die Koeffizienten der Saison-Dummys die Regressionskonstante  $a_0$ . Um aus ihnen Abweichungen von der glatten Komponente zu errechnen, ist zu berücksichtigen, dass die Summe der Abweichungen von der glatten Komponente eines Jahres Null sein muss:

$$(39) \quad \sum_{i=1}^m s_i = 0$$

Die Summe der  $m$  saisonalen Abweichungen von der Referenzsaison,  $s_i^*$ , wobei

$$(40) \quad s_i^* = s_{i0} + s_{i1} DT_i$$

ist aber nicht Null; diese Summe sei definiert als  $s$ :

$$\sum_{i=1}^{m-1} s_i^* = \sum_{i=1}^m s_i^* = s$$

Indem man  $s$  auf die linke Seite der Gleichung bringt und in die Summenformel integriert, erhält man:

$$\sum_{i=1}^m s_i^* - s = 0 = \sum_{i=1}^m \left( s_i^* - \frac{s}{m} \right) = \sum_{i=1}^m (s_i^* - \bar{s}) = \sum_{i=1}^m s_i$$

$$(41) \quad s_i = s_i^* - \bar{s}$$

Da logarithmierte Daten verwendet werden, sind die Koeffizienten  $s_i$  in der logarithmischen Skala gemessen. Der Wert  $e^{s_i}$  ist ein Index, der angibt, in welchem Verhältnis die Anlieferung im Monat  $i$  zur glatten Komponente dieses Monats steht. Der Teil der Jahresanlieferung, der auf das Monat  $i$  entfällt, ist

$$(42) \quad p_i = e^{s_i} / \sum_{i=1}^m e^{s_i}$$

Wie genau die  $s_{i0}$  und  $s_{i1}$  geschätzt werden, geben die Standardfehler der Regressionsgleichungen an. Die Varianzen der  $s_i^*$  aus (40) könnten unter Berücksichtigung der Kovarianzen zwischen den Schätzwerten für  $s_{i0}$  und  $s_{i1}$  berechnet werden. Dies erscheint allerdings als zu umständlich, zumal die meisten  $s_{i1}$  ohnehin Null sind; ein Bild über die Variabilität der Saisonkoeffizienten im Zeitablauf erhält man jedenfalls durch die konventionelle Berechnung der saisonalen Abweichungen und die grafische Darstellung der Abweichungen von ihrem Mittelwert in der Referenzperiode im Zeitverlauf (Abbildung 4).

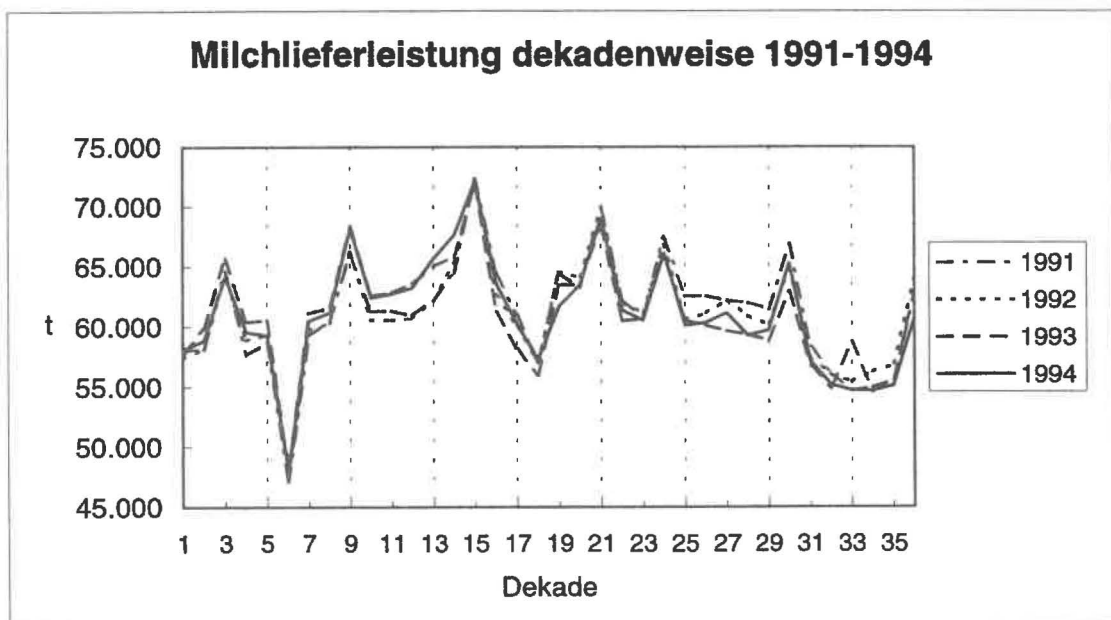
## 5. Datengrundlage

Die Milchanlieferung besteht aus den an die milchverarbeitenden Betriebe gelieferten Mengen von Milch, Rahm, Bauernbutter und Alpkäse sowie der Ortsverkaufs- und Verrechnungsmilch, ausgedrückt in Milchäquivalenten.

Die Datengrundlage zur Schätzung der saisonalen Abweichungen der Milchanlieferung stammt von der Agrarmarkt Austria (AMA, früher: Milchwirtschaftsfond). Sie erhebt die monatlichen Milchliefereien der Bauern an die Milchbe- und -verarbeitungsbetriebe und ihren Fettgehalt - aggregiert nach Bundesländern und für Österreich insgesamt. Diese Daten wurden teilweise<sup>14</sup> in den jährlichen Tätigkeitsberichten der AMA bzw. des Milchwirtschaftsfonds veröffentlicht und sind auch in ALFIS abrufbar.

Weiters wurden von der AMA die dekadenweisen Milchanlieferungen für Österreich insgesamt von 1991 bis 1994 zur Verfügung gestellt. Abbildung 1 zeigt diese Daten grafisch; sie folgen einer deutlichen Saisonfigur: Die Anlieferung ist in der sechsten am niedrigsten und in der 15. Dekade am höchsten. Ab 1995 wurden die dekadenweisen Lieferungen, gegliedert nach Bundesländern, von der AMA in den monatlichen „Marktberichten Milch und Milchprodukte“ veröffentlicht. Abbildung 2 zeigt die Verteilung der Milchanlieferungen auf die Bundesländer im Jahr 1997; demnach entfiel knapp ein Drittel der Milchliefereien auf Oberösterreich.

**Abbildung 1**

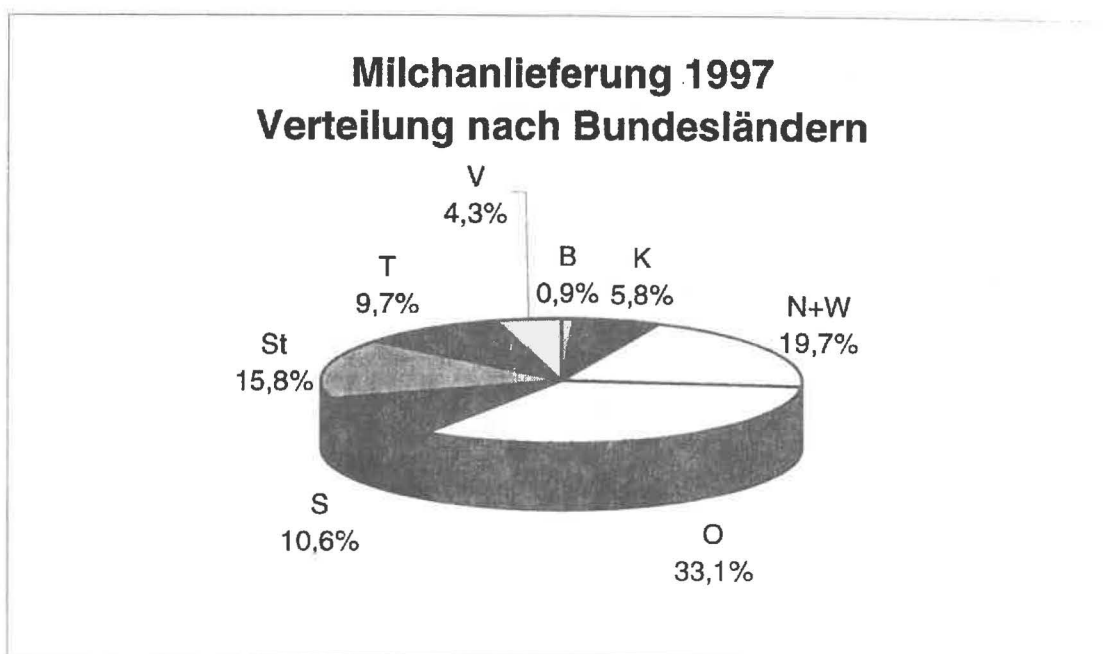


Quelle: AMA, eigene Darstellung

<sup>14</sup> Daten über den monatlichen Fettgehalt der angelieferten Milch in den Bundesländern vor 1994 und für 1996 fehlen.



Abbildung 2



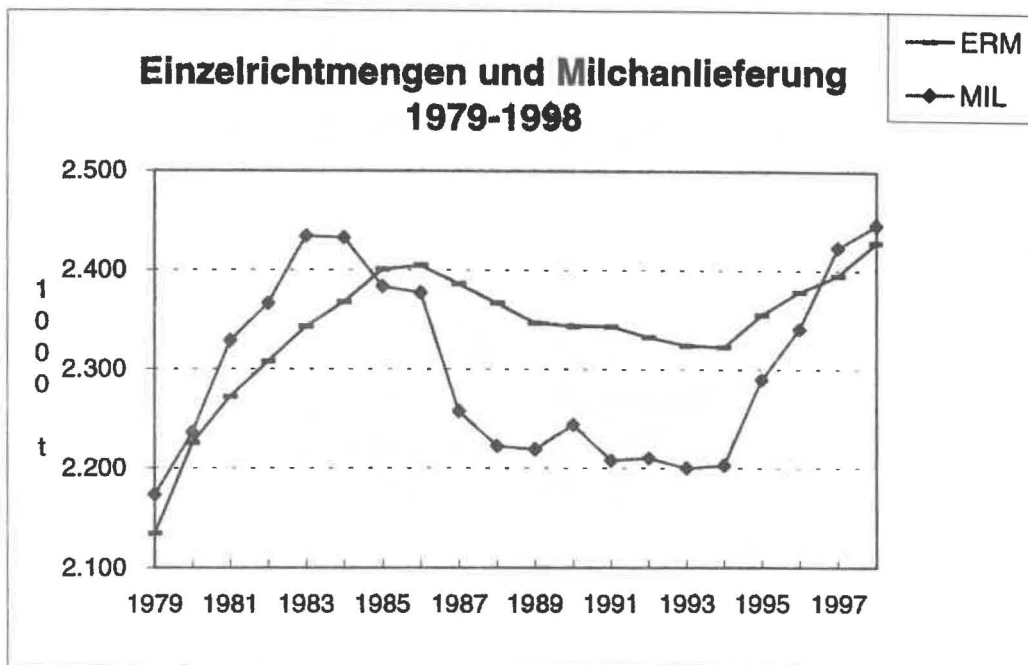
Quelle: AMA, eigene Darstellung

Eine wesentliche Bestimmungsgröße der Milchanlieferung ist die Summe der an die Bauern vergebenen Einzelrichtmengen. In den ersten Jahren nach der Einführung des Richtmengensystems hatte eine Überschreitung dieser Einzelrichtmengen für die Überlieferer den Nachteil, dass sie für die betreffenden Mengen einen Preisabzug, den „zusätzlichen Absatzförderungsbeitrag“, hinnehmen mussten. Seine Höhe hing anfangs von den auf die Lieferanten entfallenden Kosten der von der Regierung unternommenen Absatzförderungsmaßnahmen für Milchprodukte ab; später wurde auf Überlieferungen ein prohibitiv wirkender Absatzförderungsbeitrag in Höhe von ca. 85 % des Auszahlungspreises eingehoben (s. FESL 1980, ORTNER 1987); nach dem EU-Beitritt müssen die Überlieferer im folgenden Quotenjahr eine Superabgabe entrichten, wenn die überlieferten Mengen größer waren als die Mengen, mit denen die Unterlieferer unter ihrer Quote blieben.

Zu Beginn der Milchrichtmengenregelung wurden die Kosten des zusätzlichen Absatzförderungsbeitrags der Überlieferer teilweise kompensiert durch eine Aufstockung ihrer Einzelrichtmengen, die sie durch Überlieferung erwerben konnten und die zum Umfang der Überlieferung proportional war. Somit bestand auch ein Anreiz, die Einzelrichtmengen zu überschreiten; seine Größe hing vom Prozentsatz ab, mit dem Überlieferungen in Einzelrichtmengen umgewandelt wurden. Diese „Aufstockungsprozentsätze“ wurden den jährlichen Tätigkeitsberichten des Milchwirtschaftsfonds entnommen und als exogene Variable im Modell verwendet. Abbildung 3 zeigt, dass die Milchanlieferung bis 1984 höher war als die Summe der Einzelrichtmengen; dieser Umstand trat erstmals wieder 1997/98 - unter der Marktordnung der EU - ein: Die Milchanlieferung überstieg die nationale Quote mit der Folge, dass die Überlieferer eine Superabgabe von 179,94 Mill. S entrichten mussten<sup>15</sup>.

<sup>15</sup> Die Abgabe betrug 1,36 S je überlieferter Milchmenge. Siehe Anhang 5 zur Berechnung dieses Betrages.

Abbildung 3



Quelle: AMA, eigene Darstellung

Vor Ablauf eines Quotenjahres haben die Lieferanten noch die Chance, ihre Quote auszunützen und Überlieferungen zu vermeiden, wenn sie über den Stand der Lieferungen bis dahin unterrichtet sind und die richtigen Schlüsse daraus ziehen. Zu diesem Zweck errechnete die AMA das so genannte Milchbarometer - eine Prognose über das wahrscheinliche Ausmaß der Über- oder Unterlieferung insgesamt in %. Bei drohenden Überlieferungen wurden die Bauern in Zeitungen aufgefordert, ihre Lieferungen zu drosseln, um den von ihnen zu leistenden zusätzlichen Absatzförderungsbeitrag (bzw. eine Superabgabe an die EU) gering zu halten oder zu vermeiden. Im Modell zur Erklärung der Milchanlieferung wurde der Einfluss solcher Prognosen berücksichtigt, und zwar durch die Über- oder Unterlieferungen in % der Quote, die nach Bekanntwerden der Anlieferungen im April und im Mai<sup>16</sup> zu erwarten waren. Allerdings ist zu bedenken, dass die Zeit zur Korrektur der Anlieferung im Juni vermutlich bereits zu kurz ist. Die Berechnung der Über- bzw. Unterlieferungsvariablen wurde bereits im Abschnitt 4.2 beschrieben.

Zwei weitere Variablen, die im Zusammenhang mit den vergebenen Milchrichtmengen (Quoten) stehen, mussten ebenfalls in Betracht gezogen werden:

Mengen, die unter die freiwillige Lieferverzichtsaktion fielen, und

Mengen von Einzelrichtmengen, die vom Bundesministerium für Land- und Forstwirtschaft im Rahmen einer Aktion zurückgekauft wurden<sup>17</sup>.

Als exogene Variablen kommen weiters vor allem die Erzeugerpreise von Milch und anderen Agrarprodukten, die an Stelle von Milch produziert werden können, und Variablen, die politische und wirtschaftliche Rahmenbedingungen beschreiben, in Betracht. Der Erzeugerpreis der Milch

<sup>16</sup> Nach dem EU-Beitritt (1996) bis Jänner bzw. bis Feber; 1995: Null.

<sup>17</sup> Die Teilnahme an der freiwilligen Lieferverzichtsaktion 1994/95 ist im Tätigkeitsbericht für Milch der AMA nicht ausgewiesen; daher wurde angenommen, dass der tatsächliche Lieferverzicht (wie im Vorjahr) um 18 % über den Anmeldungen dafür lag (das ergab 144.969 t für das volle Quotenjahr).

wurde in ALFIS aus seinen Komponenten - Grundpreis, Betriebsleistung, Fetteinheitenpreis, Eiweißeinheitenpreis, Fettgehalt und Eiweißgehalt der angelieferten Milch<sup>18</sup>, Zuschlag für erste Qualität, Mehrwertsteuer, staatliche Stützung für Grundpreis und Fetteinheitenpreis (bis 1983), Krisengroschen, Werbegroschen und Milchleistungskontrollgebühr - errechnet und um den jeweils gültigen Allgemeinen Absatzförderungsbeitrag vermindert. Nach dem EU-Beitritt wurde der von der AMA erhobene Auszahlungspreis ab Hof einschließlich der degressiven Ausgleichszahlungen des Bundes und der Länder verwendet (Quelle: Marktberichte der AMA<sup>19</sup>).

Die Preise je kg Lebendgewicht von Kälbern, Stieren und Schweinen wurden monatlich vom ÖSTAT erhoben. Sie wurden wie der Erzeugerpreis der Milch mit dem Verbraucherpreisindex zu realen Preisen umgerechnet. Ebenso deflationiert wurden die Prämien für Mutterkuhhaltung, Kälbermast und männliche Rinder; diese Prämien sind ein Maß für den Anreiz, von der Milchproduktion auf eine Fleischproduktion überzugehen oder die Milchanlieferungen durch die Verfütterung von erzeugter Milch zu drosseln.

Die Berechnungen erfolgten mit dem PC-Programm RATS Version 4.2. Da die Milchquotenregelung im Juli 1978 eingeführt wurde und zur Bestimmung gleitender Durchschnitte die Daten des ersten Jahres gebraucht werden, beginnt die Referenzperiode für die Parameterschätzung frühestens im Juli 1979 und umso später, je länger die ins Modell aufgenommenen Variablen verzögert werden. Die Referenzperiode endet im Oktober 1998. Der Wert des Trends im Jänner 1999 ist 247. Statistiken der verwendeten Variablen sind in Tabelle A5 (im Anhang) gegeben.

Die Jahresdurchschnittswerte der betreffenden Daten sind in den Tabellen 1 und 2 gegeben.

---

<sup>18</sup> Dabei wurde der Jahresdurchschnitt auf die Monate verteilt; von diesen Monatswerten wurden fünfmonatige zentrierte gleitende Mittel gebildet, um gleitende Übergänge zwischen diesen "Monatswerten" herzustellen.

<sup>19</sup> Die degressiven Ausgleichszahlungen der Länder für Milch 1995 und 1996 wurden den Grünen Berichten des BMLF entnommen. Sie betrugen 7,28 bzw. 8,09 Groschen/kg, die in allen Monaten des jeweiligen Jahres verwendet wurden.

Tabelle 1

<b>Milchquoten, Milchanlieferung, Erzeugerpreise für Milch und andere Agrarprodukte sowie der Verbraucherpreisindex</b>							
	<i>Richt- mengen</i>	<i>Milchan- lieferung</i>	<i>Milch- preis</i>	<i>Kälber- preis</i>	<i>Stier- preis</i>	<i>Schwei- nepreis</i>	<i>VPI</i>
	<i>1000 t</i>	<i>1000 t</i>	<i>S/kg</i>	<i>S/kg</i>	<i>S/kg</i>	<i>S/kg</i>	<i>1986</i>
1979	2.134	2.173	3,66	38,59	23,52	17,73	72,84
1980	2.225	2.236	3,80	40,57	23,79	19,70	77,45
1981	2.272	2.328	4,02	41,23	25,05	22,21	82,74
1982	2.307	2.366	4,20	41,96	26,40	19,92	87,25
1983	2.343	2.434	4,33	42,88	27,67	20,64	90,16
1984	2.368	2.433	4,55	42,29	28,04	21,46	95,26
1985	2.400	2.383	4,55	40,36	27,95	19,37	98,30
1986	2.404	2.377	4,62	41,19	26,70	20,48	99,97
1987	2.386	2.257	4,64	39,51	25,68	20,64	101,42
1988	2.366	2.222	4,92	41,65	25,98	18,92	103,36
1989	2.347	2.219	5,01	44,03	27,96	20,31	106,00
1990	2.343	2.244	5,36	44,61	28,03	21,11	109,47
1991	2.343	2.208	5,52	42,32	27,41	21,46	113,12
1992	2.332	2.210	5,70	41,86	26,12	21,68	117,68
1993	2.324	2.200	5,74	42,87	26,06	19,73	121,94
1994	2.322	2.203	5,79	44,20	26,22	19,85	125,55
1995	2.355	2.290	4,65	38,42	21,63	15,91	128,38
1996	2.378	2.340	4,47	32,52	19,57	17,38	130,75
1997	2.395	2.423	4,26	30,58	19,95	18,70	132,52
1998	2.428	2.446	4,15	35,18	20,64	13,59	133,73

Quellen: AMA; ÖSTAT

Tabelle 2

<b>Jahresdurchschnittswerte von anderen die Milchanlieferung beeinflussenden Variablen</b>							
	<i>Frw. Lieferverzicht</i>	<i>D-Quote</i>	<i>Rinderprämien</i>	<i>Rückkaufaktion</i>	<i>Aufstokkungs-%</i>	<i>Überlieferung bis April</i>	<i>Überlieferung bis Mai</i>
	1000 t	1000 t	Mio. S		%		
1979	0	0	56	155	2,0%	3,0%	3,6%
1980	0	0	73	155	17,8%	1,8%	2,2%
1981	0	0	74	155	26,4%	0,6%	1,4%
1982	0	0	86	155	29,1%	3,5%	4,0%
1983	0	0	104	155	25,1%	3,4%	4,2%
1984	0	0	139	155	20,3%	3,3%	3,6%
1985	0	0	136	134	13,8%	1,8%	2,0%
1986	0	0	155	93	0%	-0,4%	-0,5%
1987	53	0	205	36	0%	1,5%	1,3%
1988	99	0	201	0	0%	-5,4%	-5,9%
1989	100	0	190	0	0%	-2,0%	-2,5%
1990	110	0	307	0	0%	-3,0%	-3,4%
1991	124	0	330	0	0%	-1,8%	-2,5%
1992	138	0	406	0	0%	-2,2%	-2,9%
1993	144	0	477	0	0%	-1,4%	-1,9%
1994	147	0	503	0	0%	-2,5%	-2,8%
1995	36	116	1.702	0	0%	0,0%	0,0%
1996	0	165	2.394	0	0%	-1,8%	-1,8%
1997	0	166	2.143	0	0%	-0,2%	-0,1%
1998	0	165	2.411	0	0%	2,1%	1,9%

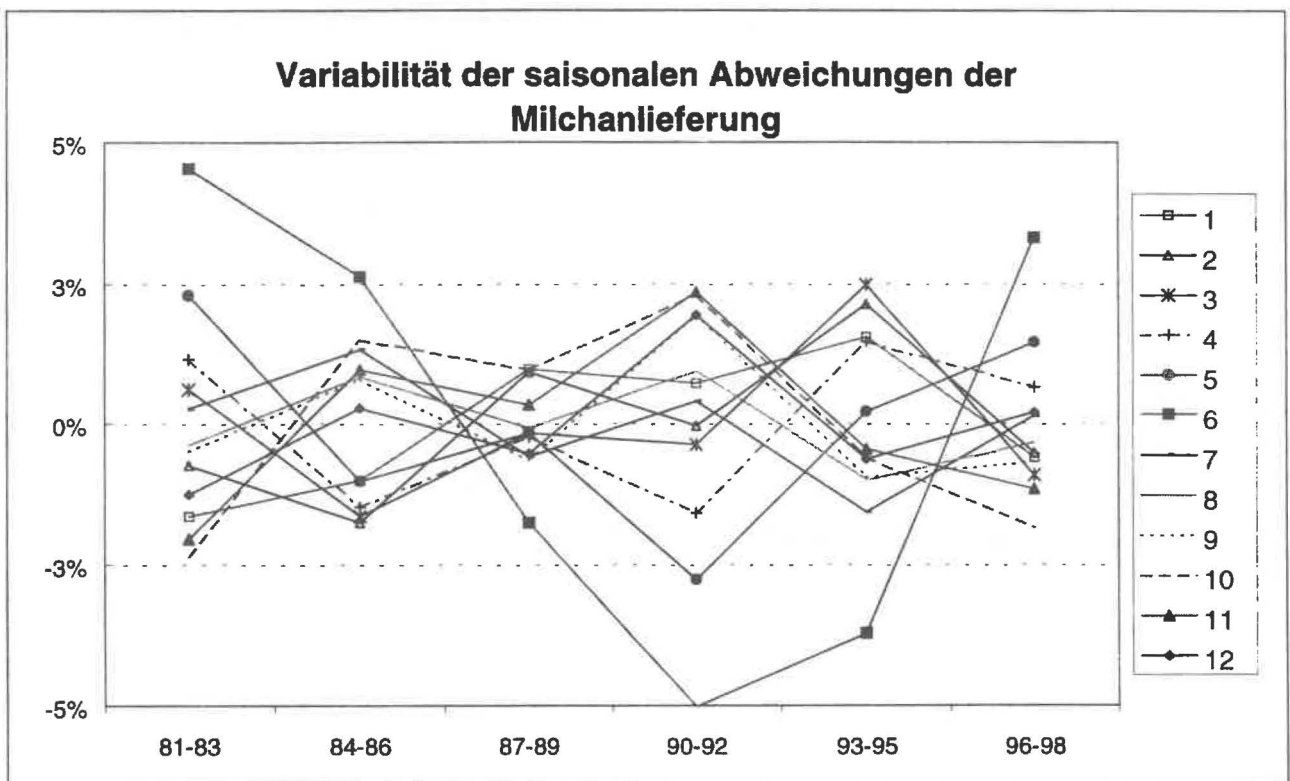
Quellen: AMA; ÖSTAT; BMLF; eigene Berechnungen

## 6. Ergebnisse

### 6.1. Entwicklung der saisonalen Abweichungen

Die Ergebnisse einer konventionellen Berechnung der Saisonfigur<sup>20</sup> sind in Tabelle 3 dargestellt; wie sich ihre dreijährigen Durchschnitte im Vergleich dazu entwickelten, zeigt Abbildung 4. Diese Abbildung macht deutlich, dass die dreijährigen Durchschnitte von saisonalen Abweichungen in einer Bandbreite von  $\pm 3\%$  schwankten, während die Abweichungen im Mai und Juni diese Bandbreite sogar überschritten. Die saisonale Abweichung der Milchanlieferung im Juni machte eine deutliche Ab- und Aufwärtsbewegung mit: Sie war von 1988 bis 1994 verhältnismäßig kleiner, vorher und nachher verhältnismäßig größer als im Durchschnitt der für diese Berechnungen gewählten Referenzperiode<sup>21</sup>; sie bewegte sich in einem Bereich zwischen  $+11,1$  und  $-3,4\%$  (1980 bzw. 1993). Außer für den Juni und allenfalls den Mai, der eine ähnliche, aber weniger ausgeprägte Entwicklung beschreitet, gibt diese Analyse keine klaren Hinweise darauf, ob die saisonalen Abweichungen einem bestimmten Trend folgen.

**Abbildung 4** Abweichungen der dreijährigen Mittelwerte der saisonalen Abweichungen von ihrem Durchschnitt 1/1981-6/1998



Quelle: Eigene Darstellung

Im Folgenden werden die Ergebnisse der ökonometrischen Schätzung der Regressionskoeffizienten besprochen; ihre Details sind in den Anhangtabellen 1 bis 3 angeführt. In diesen Tabellen ist zu beachten, dass RATS bei Regressionen mit einer Korrektur für autokorrelierte Fehlervariable (Schätzung mit der Hildreth-Lu-Methode) falsche Werte für die Standardabweichung der

<sup>20</sup> Ausgedrückt in natürlichen Logarithmen des Verhältnisses der Milchanlieferung eines Monats zum zentrierten arithmetischen Mittel über 12 Monate; den anderen Modellen liegt das geometrische Mittel zu Grunde.

<sup>21</sup> Weil dafür bereits Daten bis Ende 1998 zur Verfügung standen, konnten gleitende Mittel bis Juni 1998 berechnet werden.

Fehler und die Summe der quadrierten Fehler ausgibt. Um vergleichbare Statistiken zu erhalten, wurden deren Werte (im Textteil der Studie), die sich auf die Referenzperiode beziehen, für den Zeitraum von Jänner 1983 bis Juni 1998 berechnet. Die Prognosen für Juli bis Dezember 1998 beziehen sich auf einen Zeitraum, der außerhalb der Referenzperiode für die Schätzung der Modellparameter liegt. Vor allem im Fall des Saisonbereinigungsmodells hängen die Ergebnisse der Prognosen stark davon ab, in welchem Monat sie ihren Ausgangspunkt nehmen.

## 6.2. Saisonbereinigungsmodell

Die Schätzung von Gleichung (29) mittels multipler Regression ergibt eine Fehlervariable  $u$  mit einer Standardabweichung von 2,58 %. Die vom Idealwert weit entfernte Durbin-Watson Statistik von 0,54 zeigt, dass diese Fehlervariable stark autokorreliert ist; daher lassen sich die Saisonkoeffizienten mittels Verallgemeinerter Kleinsten Quadrate effizienter schätzen, und man erhält das in Tabelle A1 (im Anhang) angeführte Ergebnis. Die Standardabweichung des Restfehlers  $\varepsilon$  dieses Modells ist mit 1,76 % wesentlich niedriger (vgl. die Gleichungen 7 bzw. 25).

Folgt man diesem Ergebnis, dann haben sich die saisonalen Abweichungen seit 1980 im Durchschnitt kaum verändert: Sie blieben mit Ausnahme der Abweichung im Juni, die einem positiven Trend folgt (Variable JUNT), konstant. Überdurchschnittliche Lieferungen bis Mai (bzw. Feber) relativ zu den vergebenen Einzelrichtmengen (Variable BMAP) wirkten sich negativ auf die Lieferungen im Juni (bzw. März) aus; Überlieferungen bis April (bzw. Jänner) hatten ebenfalls einen negativen Einfluss auf die Lieferungen im Juni (bzw. März). Der Einfluss der Überlieferungen ist statistisch nicht signifikant; Unterlieferungen hatten offenbar keinen Einfluss auf die Milchlieferung. Die saisonalen Abweichungen im April, September und Oktober waren mit einer Wahrscheinlichkeit von 67 % nicht von Null verschieden, d. h., sie wichen vom gleitenden Mittel der Milchlieferleistung weniger ab als die Fehlervariable von Null; aber nur die Saisonfigur von September wurde auf Null gesetzt.

## 6.3. Kausales Modell

Die Fehler des kausalen Modells waren ebenfalls autokorreliert, mit einer Durbin-Watson Statistik von 1,20 aber weniger stark. Die Fehlervariable dieses Modells hat eine im Vergleich zum Saisonbereinigungsmodell deutlich geringere Varianz (Standardabweichung 1,83 %). Die mit OLS geschätzte Regressionsgleichung des kausalen Modells enthält deutlich mehr exogene Variablen, obwohl ein Einfluss der Über- und Unterlieferungsvariablen nicht nachgewiesen werden konnte.

Bei der Schätzung mit Verallgemeinerten Kleinsten Quadraten zeigt sich, dass einige dieser exogenen Variablen doch keinen signifikant von Null verschiedenen Einfluss auf die Milchlieferung haben. Daher wird mit diesem Modell auch keine wesentlich bessere Übereinstimmung mit den Daten erreicht: Die Standardabweichung des Restfehlers beträgt 1,75 %. Das kausale Modell hat aber eine deutlich geringere Autokorrelation der Fehler aufzuweisen, was sich auf die Genauigkeit der Prognosen in die Zukunft mit diesem Modell, das in Tabelle A2 im Anhang präzisiert ist, positiv auswirken sollte. Im kausalen Modell wird die Milchlieferung neben der Saisonfigur, die in allen Monaten ausgeprägt ist und über die Jahre konstant bleibt, von folgenden Variablen beeinflusst:

Milchpreis real, verzögert um 21 Monate	lrMIP
Prämien für Rinder real (Mutterkuhhaltung und Kälbermast), aktuell und verzögert um 13 Monate	rRPR
vergebene Einzelrichtmengen, verzögert um 8 Monate	ERM



vergebene D-Quoten, verzögert um 3 und 21 Monate	DQU
dem Aufstockungsprozentsatz, d.i. das Verhältnis zwischen neu ausgegebenen Einzelrichtmengen und den sie begründenden Überlieferungen, verzögert um 9 und 21 Monate	AST
den zur Teilnahme an der freiwilligen Lieferverzichtsaktion ange- meldeten Mengen	FLV

Die Höhe des Einflusses einer Variable misst ihr Koeffizient in der Regressionsgleichung, der in Tabelle A2 (im Anhang) gegeben ist. Die Koeffizienten der logarithmierten Variablen sind Elastizitäten<sup>22</sup>. In diesem Modell wurde kein Einfluss der Rückkaufaktion auf die Milchlieferleistung festgestellt, während jener der fast zeitgleich und gegenläufig wirkende Einfluss des Aufstockungsprozentsatzes beachtlich ist; die anfangs gegebene Aufstockungsmöglichkeit der Quoten stellte also einen bedeutenden Anreiz zur Überlieferung dar. Ein höherer realer Milchpreis und höhere Rinderprämien hatten einen positiven Einfluss auf die Milchanlieferung. Höhere Direktvermarktungsquoten verminderten die Milchanlieferung (mit einer leichten Verzögerung); wenn die Direktvermarktungsquoten vor 21 Monaten hoch waren, wirkte sich dies positiv auf die aktuelle Milchanlieferung aus: Ein Teil dieser Quoten wurde im Lauf des Jahres zu Anlieferungsquoten umgewandelt. Der freiwillige Lieferverzicht wirkte sich negativ auf die Anlieferungen aus. Dagegen zeitigten drohende Über- oder Unterlieferungen der Milchquote am Ende des Quotenjahres keine signifikante Reaktion der Erzeuger in Bezug auf ihre Milchanlieferung.

#### 6.4. Partielles Anpassungsmodell

Wie beim kausalen Modell war es auch hier nicht möglich, die Autokorrelation der Fehler zu beseitigen. Da die Durbin-Watson Statistik des mit OLS geschätzten Modells 1,07 beträgt, kann die Effizienz der Schätzung durch Berücksichtigung der Autokorrelation der Fehler verbessert werden. Auf diese Weise wurde das Modell mit der kleinsten Streuung der Fehler  $u$  (1,75 %) und Restfehler  $\varepsilon$  (1,55 %) entwickelt. In diesem Modell, das in Tabelle A3 im Anhang präzisiert ist, wird die Milchanlieferung von folgenden Variablen beeinflusst:

<i>Saisonfigur</i> mit zunehmender Abweichung im Juni	JUNT
gleitende Durchschnitte der <i>Aufstockungsprozentsätze</i> , verzögert um 4 und 17 Monate	sAST
gleitende Durchschnitte der durch die <i>Rückkaufaktion</i> gekauften Mengen, verzögert um 9 Monate	sRKF
gleitende Durchschnitte der Mengen für den freiwilligen <i>Lieferver-</i> <i>zicht</i> , verzögert um 12 Monate	sFLV
gleitende Durchschnitte der logarithmierten realen <i>Rinderprämi-</i> <i>en</i> , verzögert um 21 Monate	lsrRPR
reale <i>Milchpreise</i> , verzögert um 6 und 20 Monate	lrMIP
reale Rinderprämien	rRPR
vergebene Einzelrichtmengen, verzögert um 10 Monate	ERM
Mengen für den freiwilligen Lieferverzicht	FLV

Dieses Modell ist in der Referenzperiode das am genauesten prognostizierende, hat aber eine geringfügig größere Autokorrelation der Fehler als das kausale Modell.

<sup>22</sup> D.h., eine Zunahme der Variable um 1 % ändert die Milchlieferungen um den Prozentsatz, den der Koeffizient angibt.



## 6.5. Vergleich der Schätzergebnisse

Wie Tabelle 3 zeigt, trägt die Autokorrelation der Fehler  $u_t$  zu einem beachtlichen Teil zur Varianz dieser Fehler bei; mit über 54 % ist dieser Teil beim Saisonbereinigungsmodell am größten. Die Prognose der Milchlieferung in folgenden Monaten lässt sich daher stark verbessern, wenn man den Fehler der letzten Prognose

$$u_t^y = y_t - \bar{y}_t - s_t^y$$

berechnet und die Beziehung

$$u_{t+1} = \rho u_t + \varepsilon_{t+1}$$

zwischen den Fehlern zur Prognose der Milchlieferung in den folgenden Monaten verwendet. Dies gilt auch für die beiden Erklärungsmodelle; mit diesen gelingt es, die Varianz der unkorrelierten Prognosefehler  $\varepsilon_t$  im Vergleich zum Saisonbereinigungsmodell weiter (um 1 bzw. 22 %) zu verringern. Durch die Aufnahme von erklärenden Variablen ins Modell wird nur ein Teil der Autoregression der Fehler, aber bei weitem nicht die ganze, aufgefangen. Das ist ein Zeichen dafür, dass weitere Variablen von Einfluss auf die Milchlieferung waren, die nicht im Modell berücksichtigt wurden oder werden konnten, weil Daten und Informationen darüber fehlen.

**Tabelle 3 Statistiken über die Regressionsgleichungen der Modelle**

Modell	Standardabweichung der Fehler ( $u_t$ )	Durbin-Watson-Statistik	Autokorrelationskoeffizient der Fehler ( $\rho$ )	Standardabweichung der Restfehler ( $\varepsilon_t$ )
Saisonbereinigung	2,580	0,54	0,747	1,756
kausal	1,827	1,21	0,536	1,747
partielle Anpassung	1,752	1,07	0,547	1,551

## 6.6. Prognosen und Prognosefehler

Der Abstand zwischen den Mittelwerten der Saisonfigur und der anderen im Saisonbereinigungsmodell enthaltenen Variablen und ihren Werten im Durchschnitt der Monate von Juli bis Dezember 1998 ist gering: Der Faktor  $f_0$  in Gleichung (26) ist 1,0506; somit ist die Standardabweichung der Prognosen für diese Zeitspanne nur um 2,5% höher als im Durchschnitt der Referenzperiode.

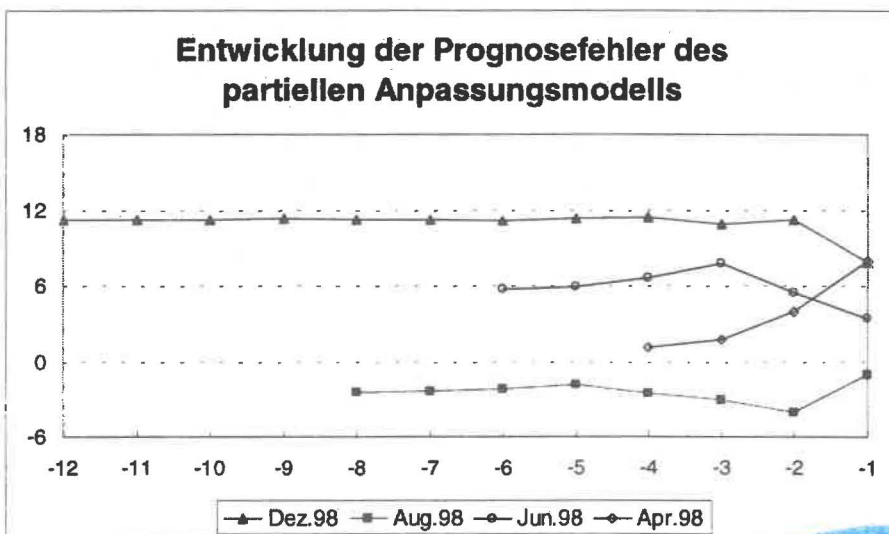
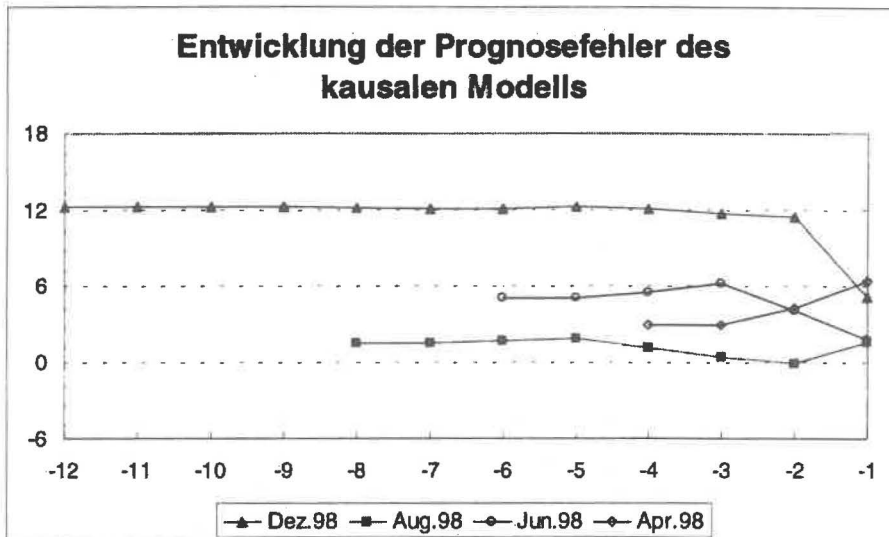
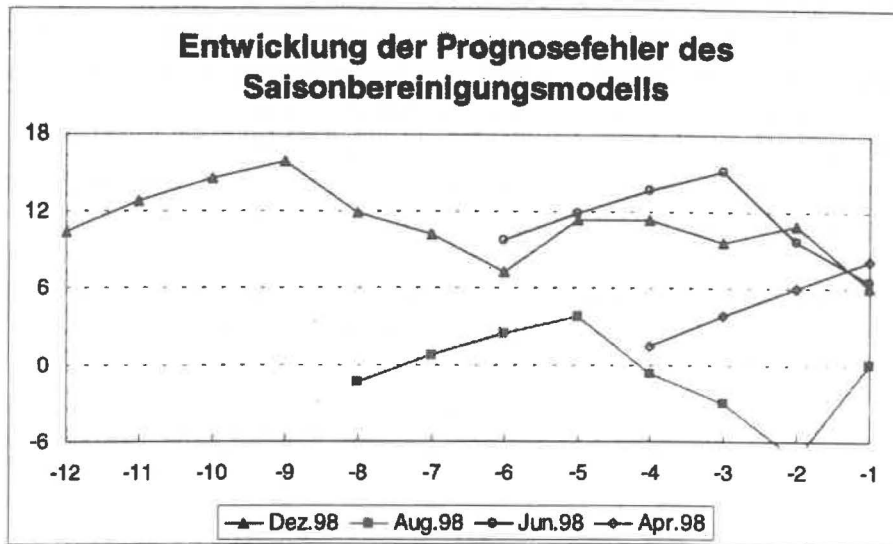
Da alle Modelle autokorrelierte Fehler enthalten, gibt es in jedem Fall (auch bei gleichen exogenen Variablen) unterschiedliche Prognosewerte in Abhängigkeit davon, in welcher Periode man mit der Prognose beginnt. Zur Bestimmung der Größe dieser Unterschiede wurden Prognosen bis Dezember 1998 berechnet; bis zu diesem Zeitpunkt standen beobachtete Daten für die erklärenden Variablen und die zu erklärende Variable zur Verfügung. Bei der ersten Prognose wurde angenommen, dass Daten bis Dezember 1997 bekannt sind; dies ergibt für Dezember (April) 1998 eine Prognose beruhend auf Daten, die 12 (bzw. 4) Monate zurückliegen. Der zweiten Prognose wurden Daten bis Jänner 1998 zugrundegelegt; dies ergibt für Dezember (April) 1998 eine Prognose mit 11 (bzw. 3) Monate zurückliegenden Daten. Mit zunehmend verfügbaren Daten reichen die Prognosen immer weniger weit in die Zukunft und sollten daher entsprechend genauer werden; ein Teil dieser Prognosen wurde anhand von Daten erstellt, die außerhalb der Referenzperiode beobachtet wurden (Juli bis Dezember 1998).

In der Abbildung 5 werden die Fehler der Prognosen für einige ausgewählte Monate, nämlich April, Juni, August und Dezember 1998, in Abhängigkeit davon dargestellt, wie weit die betref-

fende Prognose in die Zukunft reicht. Die Abbildung bestätigt die Erwartung, dass die Prognosefehler des Saisonbereinigungsmodells besonders stark wechseln. Nicht generell bestätigt wird die Erwartung, dass die Prognosefehler mit näher rückendem Prognosehorizont kleiner werden. Betrachtet man z. B. die Milchanlieferung im Dezember 1998, dann zeigt sich, dass sie deutlich (im Saisonbereinigungsmodell um bis zu 16.000 t) über den Prognosewerten für diesen Monat lag; der Prognosefehler verminderte sich erst (auf 6.000 t), als der Prognose die Daten über die Milchanlieferungen bis November 1998 zu Grunde gelegt wurden. Die Prognose für April 1998 wurde dagegen mit zunehmend verfügbaren Daten immer schlechter, und jene für Juni wurde erst in den letzten beiden Monaten besser; die Milchanlieferung im August wurde sowohl unter- als auch überschätzt. Erst bei einem Prognosehorizont von einer Periode verminderten sich die Prognosefehler, wenn auch nicht in jedem Fall; dabei kommt die autokorrelierte Fehlervariable zur Wirkung (27).

Die Abbildung 5 zeigt wesentlich stabilere Prognosewerte der kausalen Modelle, deren glatte Komponente von exogenen Variablen abhängt und deren Fehler weniger stark autokorreliert sind. Das partielle Anpassungsmodell scheint geringere Prognosefehler zu haben als die beiden anderen Modelle. Aber alle Modelle unterschätzten die Milchanlieferungen im April, August und Dezember 1998.

**Abbildung 5 Die Prognosefehler der drei Modelle in Abhängigkeit von der Verfügbarkeit von Daten für vorangegangene Perioden**

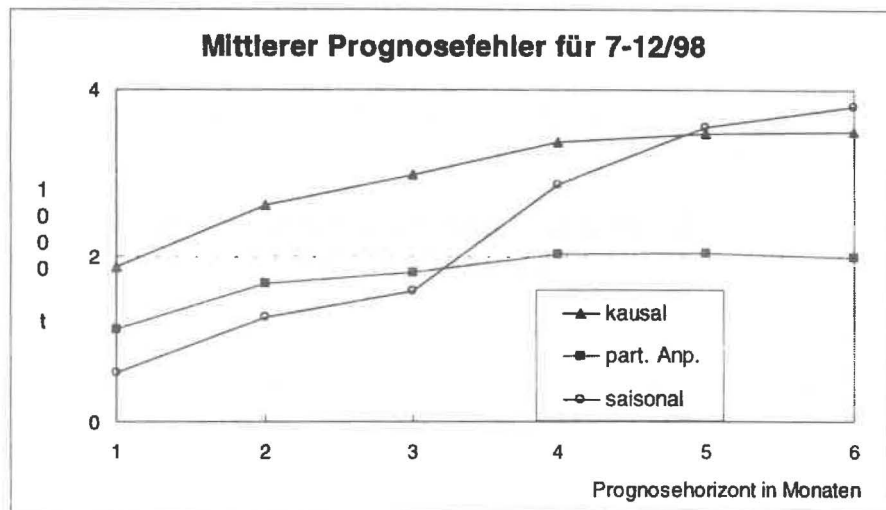


Quelle: Eigene Berechnungen



In Abbildung 6 wird dargestellt, wie sich die Prognosefehler der Prognosen für die Monate im zweiten Halbjahr von 1998 in Abhängigkeit davon veränderten, auf wie weit in der Zukunft liegende Perioden sich diese Prognosen bezogen. Die Prognosen für den ersten (den nächstfolgenden) Monat erwiesen sich als die genauesten; sie verfehlten die beobachtete Milchanlieferung im Durchschnitt nur um 600 bis 1.900 t. Für Prognosen bis zu drei Monaten im Voraus war das Saisonbereinigungsmodell den anderen Modellen überlegen. Für weiter in der Zukunft liegende Monate waren die Prognosen mit dem partiellen Anpassungsmodell genauer; die Prognosen der Milchanlieferung über sechs Monate gelangen mit dem kausalen Modell besser als mit dem Saisonbereinigungsmodell.

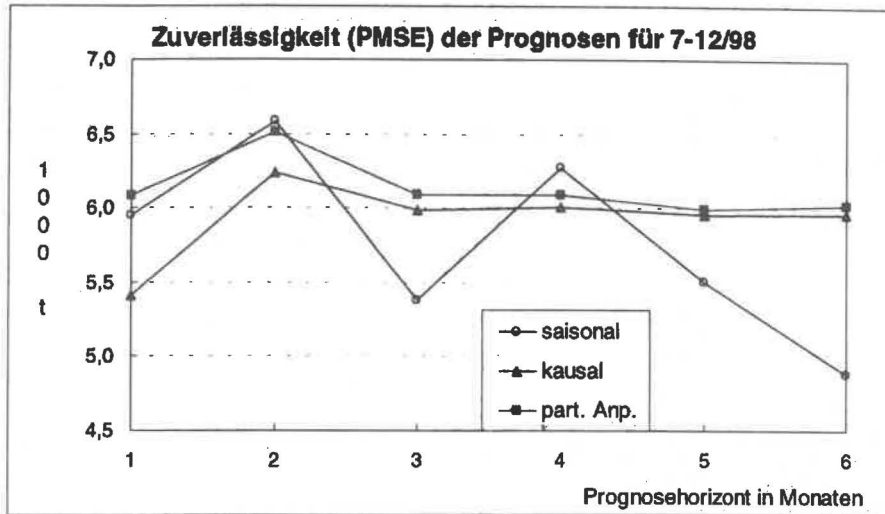
**Abbildung 6 Die durchschnittlichen Prognosefehler der drei Modelle in den Monaten Juli bis Dezember 1998 in Abhängigkeit von der Länge des Prognosehorizontes**



Quelle: Eigene Berechnungen

Der positive Eindruck, den das Saisonbereinigungsmodell anhand des durchschnittlichen Prognosefehlers hinterlässt, wird verwischt, wenn man die Varianz dieser Prognosefehler in Betracht zieht. Ein Vergleich der Modelle nach diesem Kriterium – der Zuverlässigkeit der Prognosen (ihr „predicted mean squared error“) – für das zweite Halbjahr 1998 ist in Abbildung 7 dargestellt. Demnach lieferte das kausale Modell kurzfristig (für bis zu zwei Monate im Voraus) die zuverlässigsten Prognosen, während das Saisonbereinigungsmodell für drei, fünf und sechs Monate im Voraus am zuverlässigsten prognostizierte. Angesichts dieser widersprüchlichen Ergebnisse, die für eine spezifische Zeitspanne gefunden wurden, kann man nicht feststellen, welches Modell für Prognosen in die Zukunft besser geeignet ist. Wahrscheinlich ist, dass sich das gleitende Mittel der Milchanlieferung im ersten Halbjahr 1998 zufällig auf einem Pfad bewegte wie fünf bis sechs Monate später, mit dem Effekt, dass das Saisonbereinigungsmodell relativ zuverlässige Prognosen für diesen Prognosehorizont lieferte.

**Abbildung 7 Die Standardabweichung der Prognosefehler der drei Modelle in den Monaten Juli bis Dezember 1998 in Abhängigkeit von der Länge des Prognosehorizontes**



Quelle: Eigene Berechnungen

Die drei Modelle unterscheiden sich also bezüglich der Zuverlässigkeit ihrer Prognosen für das zweite Halbjahr 1998 relativ wenig. Die Überlegenheit der kausalen Modelle in nur zwei bis drei von sechs Prognosehorizonten reicht nicht, um ihre Verwendung nahe zu legen, zumal sie auch mit einem deutlich höheren Aufwand verbunden ist. Wenn sich die Rahmenbedingungen nicht wesentlich ändern, sind kurzfristige Prognosen mit einem Saisonbereinigungsmodell offenbar ähnlich genau oder sogar genauer, obwohl sie in engerem Zusammenhang mit dem Ausgangsmonat der Prognose stehen und kurzfristig entsprechend stärkeren Schwankungen unterliegen. Die folgende Analyse beschränkt sich daher auf Prognosen mit Saisonbereinigungsmodellen. Deren wesentliche Eigenschaft ist die Saisonfigur, die auf verschiedene Weise geschätzt werden kann und die ebenfalls entsprechende Schwankungen in der Zeit aufweist (siehe Abbildung 4).

## 6.7. Vergleich der geschätzten Saisonfiguren

Im Gegensatz zu den Prognosefehlern unterscheiden sich die Modelle merklich hinsichtlich der für 1998 prognostizierten saisonalen Abweichungen von der glatten Komponente, wie Tabelle 4 und Abbildung 8 zeigen. Dabei ist zu beachten, dass die glatte Komponente in den drei Modellen unterschiedlich definiert ist: im Saisonbereinigungsmodell als gleitendes Mittel der aktuellen und der elf vorhergegangenen Monatsdaten und in den Erklärungsmodellen als Ergebnis der Reaktion der Milcherzeuger auf die bis zum jeweils aktuellen Zeitpunkt herrschenden Rahmenbedingungen. Die glatte Komponente der konventionell berechneten Saisonfigur ist der Mittelwert aus der Milchanlieferung in der aktuellen und den 5,5 vorhergehenden sowie nachfolgenden Monaten.

**Tabelle 4 Saisonale Abweichungen der Milchanlieferung in Österreich von der glatten Komponente, prognostiziert für 1998 mit drei Modellen, im Vergleich zur Abweichung vom zentrierten gleitenden Mittel**

Modell	Saisonale Abweichung (in %) im Monat					
	1	2	3	4	5	6
gleitendes Mittel	-3,22	-10,91	1,68	1,50	11,91	4,34
Saisonales Modell	-3,18	-10,86	1,83	1,50	12,01	3,34
Kausales Modell	-3,35	-11,34	1,23	1,13	11,60	4,02
Part. Anpassungsm.	-2,87	-10,64	1,78	1,24	11,25	1,56

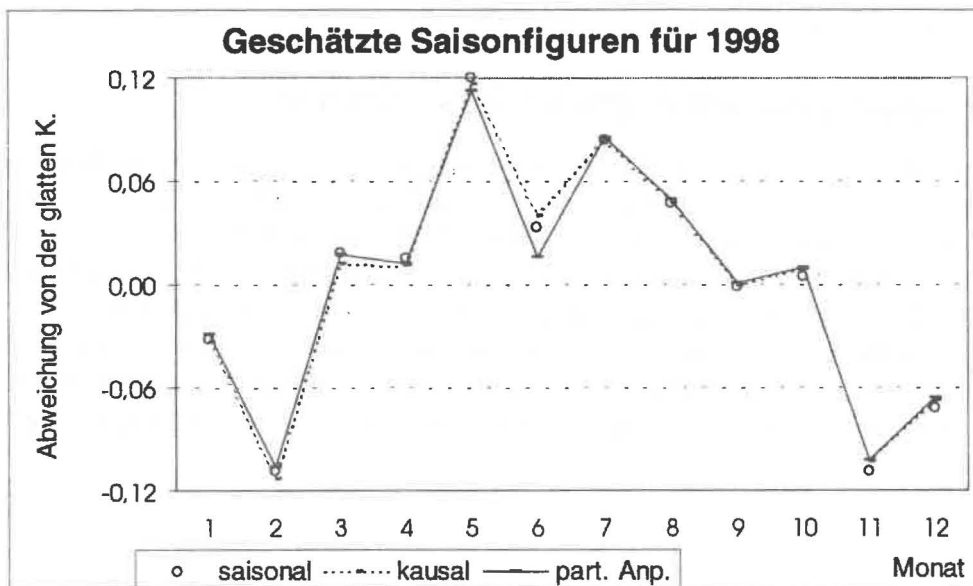
  

Modell	Saisonale Abweichung (in %) im Monat					
	7	8	9	10	11	12
gleitendes Mittel	8,09	4,44	-0,35	0,33	-10,77	-7,04
Saisonales Modell	8,39	4,73	-0,17	0,48	-10,86	-7,19
Kausales Modell	8,36	4,69	-0,10	0,88	-10,33	-6,80
Part. Anpassungsm.	8,49	4,95	0,10	1,02	-10,25	-6,64

Quelle: Eigene Berechnungen

In dem Maß, in dem die glatten Komponenten der verschiedenen Modelle voneinander abweichen, unterscheiden sich auch die saisonalen Abweichungen von den glatten Komponenten. Mit den Erklärungsmodellen sollte man dabei zu einem genaueren Ergebnis kommen, denn ihre glatte Komponente kann den aktuellen Stand einer sich über mehrere Perioden (bzw. viele Monate) hinziehenden Reaktion repräsentieren; dieser Stand hängt z.B. davon ab, ob man sich in einem oder bereits in einem anderen Quotenjahr befindet. Solche (sprunghaften) Änderungen können mit einem gleitenden Mittel nicht abgebildet werden, denn der gleitende Durchschnitt über die letzten zwölf Monate zeigt den Stand der Reaktionen der Milchlieferanten auf äußere Bedingungen im Durchschnitt des abgelaufenen Jahres und kann daher nicht den aktuellen Stand dieser Reaktionen zeigen.

**Abbildung 8 Abweichungen von der glatten Komponente in den drei Modellen**



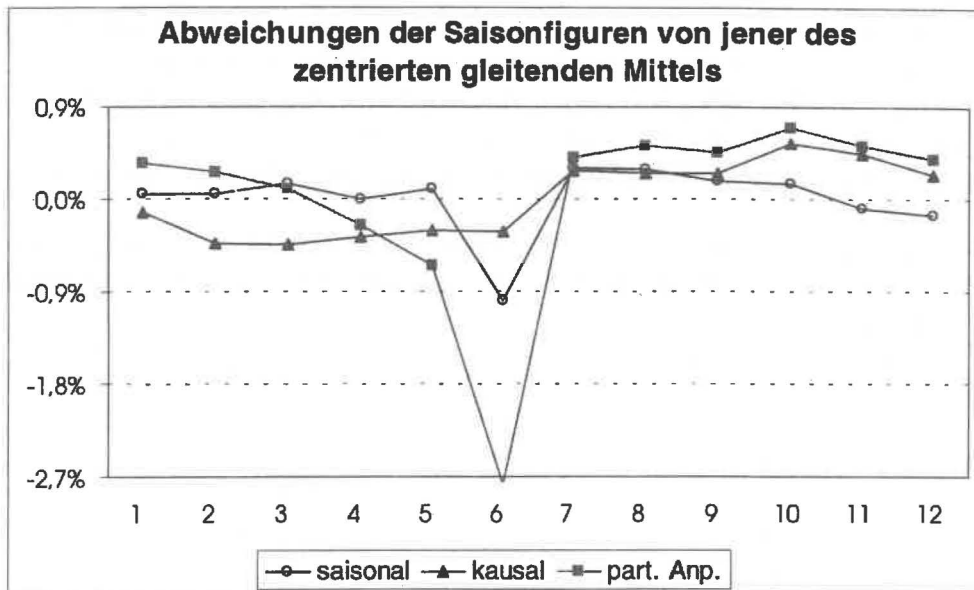
Quelle: Eigene Berechnungen

Bei Verwendung gleitender Mittel an Stelle der tatsächlichen (aber unbeobachtbaren) glatten Komponente zur Schätzung der Saisonfigur kann man daher verzerrte Ergebnisse erhalten. Die Saisonfigur eines Erklärungsmodells ist "richtiger" in dem Sinn, dass sie den Einfluss, der der



Saison zugeschrieben werden kann, isoliert und nicht den Einfluss anderer (auf die Milchlieferung Einfluss nehmender) Faktoren mit erfasst. Die Höhe möglicher Verzerrungen der mit verschiedenen Modellen geschätzten Saisonfigur bringt Abbildung 9 (für 1988) zum Ausdruck; sie zeigt, inwieweit sich die Saisonfiguren dieser Modelle von jener unterscheiden, die aus den Abweichungen von zentrierten gleitenden Mitteln berechnet wurden.

**Abbildung 9 Unterschiede zwischen den Saisonfiguren der ökonometrischen Modelle und den durchschnittlichen saisonalen Abweichungen, in % der glatten Komponente**



Quelle: Eigene Berechnungen

Die Ergebnisse der Schätzung saisonaler Abweichungen liegen demnach um bis zu 2,8 Prozentpunkte pro Monat (im Juni) auseinander. Andernfalls ist kein systematischer Unterschied zwischen den geschätzten Saisonfiguren feststellbar: Die Unterschiede bewegen sich überwiegend in einem Bereich von  $\pm 0,5$  Prozentpunkten – viel weniger, als die durchschnittliche Standardabweichung der mit der Regressionsgleichung geschätzten Koeffizienten der Sasiondummy-Variablen von ca. 1,7 %. Die saisonale Abweichung im Juni stellt aber einen Sonderfall dar: Sie wird mit dem zentrierten gleitenden Mittel am höchsten geschätzt und mit den Modellen, in denen eine trendabhängige Saisonfigur für Juni angenommen wurde, am niedrigsten. In keinem der beiden kausalen Modelle scheint eine Variable enthalten zu sein, die den Abfall und anschließenden Aufschwung der saisonalen Abweichungen im Juni (siehe Abbildung 4) erklären kann. Jenen Schätzwert der Saisonfigur im Juni, der mit der geringsten Standardabweichung behaftet ist, liefert das kausale Modell.

## 6.8. Hochrechnung auf Quotenjahre

Wenn man die je nach Modell verschiedenen Saisonfiguren dazu verwendet, von den Anlieferungen mehrerer Monate auf ein gesamtes Jahr hochzurechnen, wird man verschiedene Ergebnisse erhalten. Daher ist es notwendig zu überprüfen, wie sich die Verwendung unterschiedlicher Saisonfiguren auf die Prognoseergebnisse für einen längeren Zeitraum auswirkt. Bei Verwendung der in Tabelle 4 gegebenen Saisonfiguren unterscheiden sich die Prognoseergebnisse für ein Kalenderjahr mehr als jene für ein Quotenjahr (dieses beginnt seit dem Beitritt Österreichs zur EU 1995 im April). Um dies zu demonstrieren, betrachten wir die zu einer sol-

chen Hochrechnung benötigten kumulierten saisonalen Verteilungen der Milchanlieferung in Österreich in Tabelle 5.

Nach dem partiellen Anpassungsmodell werden 52,3 % der Milchanlieferung eines Quotenjahres von April bis September geliefert, nach dem Modell mit gleitenden Mitteln jedoch 52,5 %. Somit hat sich bis zu diesem Zeitpunkt ein Unterschied zwischen den beiden Modellen von 0,19 % der Jahresanlieferung angehäuft; mit anderen Worten: Das Modell, das auf zentrierte gleitende Mittel aufbaut, ordnet ca. 4.500 t den ersten sechs Monaten des Quotenjahres zu, die nach dem partiellen Anpassungsmodell erst in der zweiten Hälfte des Quotenjahres geliefert werden. Rechnet man daher von der Anlieferung von April bis September mit der (kumulierten) saisonalen Verteilung des Saisonbereinigungsmodells auf jene eines ganzen Jahres hoch, dann erhält man einen (im vorliegenden Beispiel) um 8.500 t niedrigeren Prognosewert als unter Verwendung der saisonalen Verteilung des partiellen Anpassungsmodells<sup>23</sup>. Diese Werte geben einen Anhaltspunkt hinsichtlich der Höhe möglicher Verzerrungen der Prognosen, die auf die ungenaue Kenntnis der glatten Komponente in zukünftigen Monaten zurückzuführen sind.

**Tabelle 5 Ab April kumulierte Prozentanteile der Monate des Quotenjahres 1998/99 an der jährlichen Milchanlieferung in Österreich nach den Ergebnissen der drei Modelle**

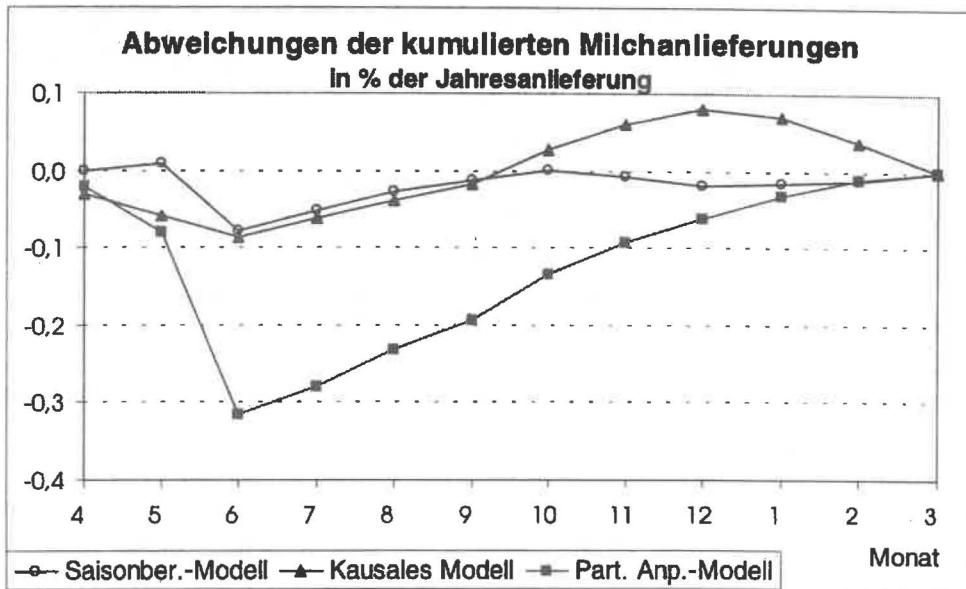
Monat	gleitendes Mittel	Saisonber.-Modell	Kausales Modell	Part. Anp.-Modell
4	8,440	8,440	8,410	8,420
5	17,806	17,815	17,747	17,726
6	26,489	26,412	26,403	26,173
7	35,505	35,453	35,443	35,226
8	44,197	44,170	44,157	43,964
9	52,482	52,470	52,464	52,288
10	60,824	60,824	60,852	60,690
11	68,289	68,283	68,350	68,196
12	76,039	76,020	76,119	75,977
1	84,090	84,074	84,159	84,058
2	91,545	91,533	91,583	91,535
3	100,000	100,000	100,000	100,000

Quelle: Eigene Berechnungen

Abbildung 10 zeigt die Unterschiede zwischen den kumulierten Anteilen der ökonometrischen Modelle und jenen, die man mit der konventionellen Methode der Berechnung saisonaler Abweichungen erhält, in Abhängigkeit vom Zeitpunkt, bis zu dem die jeweilige saisonale Verteilung kumuliert wird. Diese Unterschiede werden naturgemäß gegen Ende des Quotenjahres - dem Zeitpunkt, an dem die Prognosen am dringendsten benötigt werden - geringer; im Juni erreichen sie ihren Höchstwert mit bis zu 0,32 % der Milchanlieferung eines Jahres, d.s. ca. 7 Mill. t. Dabei zeigt sich ein gewisser Unterschied zwischen den Ergebnissen aus den Saisonbereinigungen einerseits und den kausalen Modellen andererseits: Erstere rechnen bis September mit einer höheren Milchanlieferung als letztere. Jedenfalls ergibt eine Hochrechnung mit Anlieferungsdaten bis September auf das Quotenjahr mit der Verteilung des partiellen Anpassungsmodells einen höheren Prognosewert als Hochrechnungen mit den Verteilungen der anderen Modelle.

<sup>23</sup> Wenn in diesen ersten sechs Monaten 1,200.000 t Milch geliefert wurden und dies ein Anteil von 0,52288 der jährlichen Anlieferung ist, erhält man hochgerechnet 2,295.000 t für das Jahr, mit dem Anteil von 0,52482 aber 2,286.500 t.

**Abbildung 10 Unterschiede zwischen den ab April kumulierten Anteilen an der Milchanlieferung in Österreich und den aus zentrierten saisonalen Abweichungen berechneten kumulierten Anteilen**



Quelle: Eigene Berechnungen

Zur Beurteilung einer Hochrechnung der Milchanlieferung auf ein ganzes Jahr ist es nicht nur notwendig zu wissen, wie groß die besprochenen Fehler der Schätzung der Saisonfigur sein können; es stellt sich auch die Frage, wie genau die Hochrechnung für ein Quotenjahr auf Grund der Varianz der Fehlervariablen ist. Das Saisonbereinigungsmodell hat die Fehlervariable mit der größten Varianz, nämlich eine Standardabweichung von 2,58 % einer Monatslieferung, d.s. ca. 4.960 t. Errechnet man daraus die Standardabweichung der Prognosen (mit dem Faktor 1,025) und multipliziert sie mit dem Faktor 1,96 (dem t-Wert), dann erhält man das Konfidenzintervall, das ist jener Abstand vom Prognosewert, den die tatsächliche Milchanlieferung mit 95 % Sicherheit nicht überschreiten wird. Berücksichtigt man bei der Prognose den Fehler aus der Vorperiode, dann vermindert sich die Varianz des Prognosefehlers gemäß Gleichung (28) um den Faktor  $(1-\rho^2)$ . Das Konfidenzintervall der Prognosen mit dem Saisonbereinigungsmodell für einen durchschnittlichen Monat ist somit  $\pm 6.700$  t (siehe Tabelle 6).

Bei einer Prognose der Milchanlieferung in mehreren Perioden können sich die Fehler je Periode addieren oder ausgleichen. Die Standardabweichungen von Summen und somit die Zuverlässigkeit derartiger Prognosen werden mit Gleichung (29) bestimmt; die Konfidenzbereiche von Prognosen über mehrere Monate mit dem Saisonbereinigungsmodell werden in Tabelle 6 gezeigt. Sie besagen unter anderem, dass die Wahrscheinlichkeit, dass man sich bei einer Hochrechnung der Milchanlieferung für drei Monate - z. B. für die letzten drei Monate eines Quotenjahres (d.h. für Jänner bis März, wobei die Lieferungen für die ersten neun Monate bereits bekannt sind) - um mehr als 21.700 t (11,6 % einer durchschnittlichen Monatsanlieferung) verschätzen wird, geringer als 5 % ist. Bei Verwendung des partiellen Anpassungsmodells errechnet sich ein engeres Konfidenzintervall für drei (sechs) Monate, nämlich 15.900 t (26.900 t).

**Tabelle 6: Konfidenzintervalle und Standardfehler von Hochrechnungen der Milchanlieferung mit Hilfe der saisonalen Verteilung des Saisonbereinigungsmodells<sup>1</sup>**

Hochrechnung für ... Monate	Konfidenzbereich <sup>2</sup> in t bei 95 % Sicherheit + -	Standardfehler in % einer Ø Monatslieferung
1	6.700	1,8
2	14.200	3,8
3	21.700	5,8
4	29.000	7,7
5	36.000	9,5
6	42.500	11,3

<sup>1</sup> unter der Annahme, dass dessen glatte Komponente bekannt ist, unter Berücksichtigung autokorrelierter Fehler ( $\rho = 0,75$ )

<sup>2</sup> bei einer durchschnittlichen Milchanlieferung von 2,306.000 t pro Jahr (1980-1998)

Quelle: Eigene Berechnungen

Wenn man also bei einer Hochrechnung der Milchanlieferung auf Basis eines Saisonbereinigungsmodells zu einem Ergebnis kommt, wonach die Milchanlieferung um (mindestens) die in Tabelle 6 genannten Mengen kleiner sein wird als die nationale Referenzmenge, dann ist zu 95 % sicher, dass es zu keiner Überlieferung der nationalen Referenzmenge kommen wird<sup>24</sup> – sofern man die glatte Komponente kennt. Unter dieser Bedingung zeigen die in Tabelle 6 gegebenen Konfidenzintervalle, ob und wie riskant es ist, bei einer bestimmten Hochrechnung der Milchanlieferung den Erzeugern zu empfehlen, mehr Milch zu liefern. Eine solche Empfehlung gibt ihnen die Chance, die nationale Referenzmenge besser auszufüllen, sie birgt aber auch das Risiko, dass sie die Empfehlung befolgen und auf Grund dessen die Referenzmenge überschreiten.

Die Konfidenzintervalle in Tabelle 6 wurden unter der Annahme berechnet, dass der Autokorrelationskoeffizient  $\rho$  des betreffenden Modells bekannt ist und zur Prognose (gemäß Gleichung 27) verwendet wird. Tatsächlich verfügt man aber nur über einen Schätzwert von  $\rho$ , und bei einer kurzen Referenzperiode ist laut GREENE (1993, S. 438) unklar, ob durch dessen Verwendung bessere Prognosen erhalten werden als mit einem Modell, das die Autokorrelation der Fehler vernachlässigt. Um dies und die Ergebnisse aus Tabelle 6 zu überprüfen, wurden mit den beiden geschätzten Saisonbereinigungsmodellen (mit und ohne Autokorrelation der Fehler, siehe Anhangtabelle A1) Prognosen für ein und mehrere Monate im Voraus, beginnend im Jänner 1983, berechnet. Dabei wurden Blöcke von aufeinander folgenden Monaten gebildet und ausgewertet, z.B. bei Prognosen für zwei Monate Blöcke von 1-2/83, 3-4/83 usw., für drei Monate 1-3/83, 4-6/83 usw.. Die prozentuellen Prognosefehler, die positiv oder negativ sein können, wurden blockweise addiert, sodass die Summen dieser Fehler für die jeweilige Zeitspanne gelten. Wie diese Summen variieren, ist in Tabelle 7 in Form der so genannten Zuverlässigkeit der Prognosen („predicted root mean squared error“) dargestellt.

<sup>24</sup> Diese Berechnungen beruhen auf dem Saisonbereinigungsmodell, also jenem mit dem größten Fehler. Geringere Fehler erhält man bei Verwendung eines der Erklärungsmodelle zur Prognose (ebenfalls unter Berücksichtigung der Autokorrelation der Fehler).

**Tabelle 7: Standardabweichungen der Prognosefehler aus dynamischen Prognosen über mehrere Monate (ab Jänner 1983<sup>1</sup> bis zu Dezember 1998)**

Dynamische Prognosen für ... Monate	Standardfehler in % einer durchschnittlichen Monatsanlieferung	
mit SB-Modell:	OLS	GLS ( $\rho=0,75$ )
1	2,8	2,0
2	5,5	4,8
3	7,8	7,6
4	10,7	9,1
5	13,6	12,6
6	16,3	18,4
7	17,5	15,1
8	21,2	20,7
9	19,5	16,0
10	25,6	28,5
11	26,8	21,7
12	31,6	35,0
6 <sup>2</sup>	16,0	13,8
10 <sup>3</sup>	25,5	26,2
11 <sup>3</sup>	24,4	24,6

<sup>1</sup> Prognoseblöcke mit ... Monaten, beginnend ab Jänner 1983

<sup>2</sup> Prognoseblöcke beginnend ab Feber 1983

<sup>3</sup> Durchschnitt aus fünf Prognosen mit Prognoseblöcken beginnend ab Jänner bis Mai 1983

Quelle: Eigene Berechnungen

Es zeigt sich, dass die so ermittelte Zuverlässigkeit der Prognosen für mehrere Monate davon abhängt, welche Blöcke gebildet werden, denn das Ergebnis in Tabelle 7 enthält einige Unregelmäßigkeiten. Man muss ja erwarten, dass Prognosen für mehr Monate unzuverlässiger werden. Das Ergebnis zeigt aber: Mit dem OLS-Modell waren Prognosen für neun Monate genauer als solche für acht Monate, und mit dem GLS-Modell (mit autokorrelierten Fehlern) waren die Prognosen für sieben, neun und elf Monate unerwartet genau. Klar geht aus der Tabelle hervor, dass das GLS-Modell für kürzere Zeitspannen genauer prognostiziert als das OLS-Modell. Eine alternative Berechnung für Halbjahre (mit um ein Monat verschobenen Blöcken) zeigt, dass diese Aussage für sechs Monate jedenfalls zutrifft. Sie gilt offenbar bis zu neun Monate: Zusätzliche Berechnungen mit je fünf verschiedenen Zusammensetzungen von Zeitspannen über zehn und elf Monate lassen den Schluss zu, dass eine Prognose für zehn und mehr Monate mit dem OLS-Modell, d.h. ohne Berücksichtigung autokorrelierter Fehler, genauer ist. Für Prognosezeiträume von bis zu neun Monaten empfiehlt sich also die Berücksichtigung des letzten bekannten Wertes der Fehlervariable (entsprechend der Gleichung 27); damit erhält man bessere Prognosen für die unmittelbare Zukunft, aber schlechtere Prognosen für die fernere Zukunft.

Tabelle 7 zeigt, dass der Standardfehler von Prognosen über sechs Monate zwischen 14 und 18 % einer durchschnittlichen Anlieferung je Monat lag, während gemäß Tabelle 6 ein Wert von 11,3 % erwartet wurde. Bei Prognosen über fünf Monate verhielt es sich ähnlich: Der Standardfehler betrug 12,6 % im Vergleich zu den erwarteten 9,5 %. Als eine Ursache für diese Diskrepanzen kommt in Betracht, dass der Faktor  $f_0$  aus Gleichung (26) in der Referenzperiode geringfügig höhere Werte annahm als jener, mit dem die Tabelle 6 errechnet wurde (1,0506). Eine zweite mögliche Ursache ist der Stichprobenfehler, der durch die Auswahl bestimmter Prognoseblöcke entsteht und der jedenfalls für die Unregelmäßigkeiten der Ergebnisse in Ta-

belle 7 verantwortlich ist. Die wichtigste Ursache ist jedoch der Fehler der Schätzung der glatten Komponente, der in den Ergebnissen der Tabelle 6 nicht und in jenen der Tabelle 7 doch enthalten ist. Die Entwicklung der kausalen Modelle hatte den Zweck, diesen Fehler zu verringern, was in gewissem Ausmaß auch gelungen ist.



## 7. Schlussfolgerungen

Zur Hochrechnung einer saisonalen Variable scheint es zu genügen, die "richtige" saisonale Verteilung dieser Variable zu kennen. Dabei kann eine saisonale Variable ohne die übrigen Komponenten, aus denen sie sich zusammensetzt, gar nicht prognostiziert werden; bei ihrer Hochrechnung muss man die Entwicklung ihrer glatten Komponente kennen oder prognostizieren oder eine Annahme über diese Entwicklung treffen. Bei einer Hochrechnung, die sich auf die saisonale Verteilung stützt, wird implizit angenommen, dass die glatte Komponente der zu prognostizierenden Variable auf jenem Niveau bleibt, von dem aus hochgerechnet wird; das ist gewöhnlich das Niveau, auf dem sich die glatte Komponente in den ersten  $x$  Monaten jenes (Wirtschafts-) Jahres befindet, für das die Prognose erstellt wird. Die Annahme, dass die glatte Komponente in den folgenden Monaten auf dieser Höhe bleibt, wird nicht genau zutreffen; sie ist eine erste Fehlerquelle für Prognosen aus einer Hochrechnung. Eine zweite Fehlerquelle besteht darin, daß zur Feststellung des Niveaus der glatten Komponente in den ersten Monaten des Jahres, für das eine Prognose erstellt werden soll, die saisonale Verteilung benötigt wird; diese ergibt sich aus der geschätzten Saisonfigur, die von der wahren Saisonfigur im betreffenden Jahr abweichen kann. Eine Hochrechnung stützt sich also implizit oder explizit auf Annahmen über das Niveau der glatten Komponente, statt bereits vorliegende Informationen über die Lage des Marktes und der politischen Rahmenbedingungen für die Prognose optimal zu nutzen.

Erklärungsmodelle beschreiben nicht nur die Saisonfigur, sondern auch die anderen Komponenten, die auf die Milchanlieferung Einfluss haben. Ihre Fehlerkomponenten haben eine geringere Varianz; ihre glatte Komponente muss daher stärker variieren, um in Summe die Varianz der Milchanlieferung zu ergeben<sup>25</sup>. Die Erklärungsmodelle beschreiben und prognostizieren daher auch die glatte Komponente, womit man zu anderen und (ex post) auch zu besseren Ergebnissen kommt als mit den gleitenden Mitteln, die dem Saisonbereinigungsmodell und dem beschriebenen Hochrechnungsmodell zu Grunde liegen. Für ex-ante-Prognosen stützen sich die Erklärungsmodelle auf Werte der exogenen Variablen, die ihrerseits zum Teil<sup>26</sup> prognostiziert werden müssen; ob diese Prognosen besser oder schlechter sind als die Annahme einer konstanten (oder irgendeines anderen Verlaufs<sup>27</sup> der) glatten Komponente, liesse sich nur anhand eines empirischen Vergleichs von ex-ante-Prognosen definitiv feststellen.

Schließlich erhält man mit allen drei Modellen bessere Prognosen für die nähere Zukunft (bis zu neun Monate im Voraus), wenn man den autoregressiven Verlauf der Fehlervariable wie in Gleichung (20) und (27) berücksichtigt.

Das Saisonbereinigungsmodell kann problemlos auch auf regionaler Ebene (Bundesländer) angewandt werden. Es wäre möglich, dass eine solche Differenzierung genauere Prognosen für die nationale Ebene hervorbringt. Eine Überprüfung, ob das der Fall ist, mit Daten von 1990-1994 ergab, dass die Standardabweichung der summierten Fehler 2,61 % und jene der summierten Restfehler 1,59 % beträgt. Diese Standardabweichungen sind also etwa gleich groß wie jene des Saisonbereinigungsmodells für die Milchanlieferung in Österreich<sup>28</sup>; sie könnten sich

<sup>25</sup> Vorausgesetzt, dass die Saisonfiguren in beiden Modellen den gleichen Teil der Varianz erklären.

<sup>26</sup> Im Modell vorkommende um 1 Perioden verzögerte Werte der exogenen Variablen sind für 1 zukünftige Perioden bekannt.

<sup>27</sup> der z.B. durch Trendextrapolation oder einen autoregressiven Prozess bestimmt wird oder durch eine Annahme, die auf Grund bekannter oder erwarteter Änderungen der Rahmenbedingungen plausibel erscheint.

<sup>28</sup> Vergleiche mit den Werten in Tab.1. Durch die Verschiebung von Einzelrichtmengen zwischen Bundesländern kommt es zu sprunghaften Veränderungen in deren Milchanlieferung; diese wurden durch Zusammenfassung der Bundesländer Wien und Niederösterreich sowie Burgenland und Steiermark größtenteils aufgefangen.

bei simultaner Schätzung der Koeffizienten mittels SURE<sup>29</sup> noch geringfügig vermindern. Eine Schätzung von Erklärungsmodellen auf regionaler Ebene erscheint daher und wegen des damit verbundenen erhöhten Aufwandes nicht vertretbar.

---

<sup>29</sup> Seemingly Unrelated Regressions Estimation, s. z.B. JOHNSTON 1984, S. 337

## 8. Zusammenfassung

Die vorliegende Untersuchung hatte zum Ziel, Methoden zu entwickeln und zu analysieren, mit deren Hilfe festgestellt werden kann, ob die Milcherzeuger voraussichtlich so viel Milch an die Be- und Verarbeitungsbetriebe anliefern werden, wie das die für das Quotenjahr geltende nationale Milchreferenzmenge gestattet, bzw. wie weit diese Lieferungen voraussichtlich von der nationalen Milchreferenzmenge abweichen werden. Wenn rechtzeitig und mit ausreichender Sicherheit bekannt wäre, dass eine Unterschreitung (oder Überschreitung) der Referenzmengen bevorsteht, könnten die Milcherzeuger vor Ablauf des betreffenden Quotenjahres aufgefordert werden, mehr (bzw. weniger) zu liefern, um die Milchreferenzmenge und damit ein bestimmtes Einkommenspotenzial auszuschöpfen bzw. die Bezahlung einer Superabgabe zu vermeiden.

Voraussetzung für eine derartige Empfehlung ist zumindest die Kenntnis der saisonalen Verteilung der Milchlieferleistung. Die Untersuchung zeigte,

- wie die saisonale Verteilung der Milchanlieferung geschätzt werden kann,
- dass diese Schätzung auch mit Hilfe eines einfachen Saisonbereinigungsverfahrens erfolgen kann,
- wie die saisonalen Koeffizienten zur Hochrechnung der Milchanlieferungen des gesamten Quotenjahres genutzt werden können,
- dass die Verteilung, die man bei Anwendung eines Saisonbereinigungsverfahrens erhält, möglicherweise verzerrt ist, weil sie ~~den Monaten April bis September~~ <sup>von</sup> einen höheren Anteil an der Milchanlieferung eines Jahres zuordnet; und
- wie genau die Prognosen für verschiedene Prognosehorizonte sind, wenn diese Prognosen auf Basis einer saisonalen Verteilung erstellt werden und wenn man dabei die Autokorrelation der Fehler berücksichtigt oder nicht. —

Die geschätzten Erklärungsmodelle lieferten genauere Prognosen für die Referenzperiode, aber diese Überlegenheit trat bei Prognosen für die zweite Hälfte von 1998 nicht zu Tage. Vielmehr erreichten Prognosen mit jenem Saisonbereinigungsmodell, das autokorrelierte Fehler berücksichtigt, ihr Ziel im Durchschnitt genauer. Aber diese kurzfristigen Prognosen variierten stark und unabhängig davon, mit welchem Modell sie erstellt wurden. Daher geben die vorliegenden Ergebnisse keinen Anlass, die viel komplizierteren Erklärungsmodelle einzusetzen, zumal dieser Einsatz hohe technische Anforderungen stellt und für die Implementierung und Aktualisierung des Modells ein hoher Zeitverbrauch zu veranschlagen ist. Um eine endgültige Entscheidung für oder gegen die Verwendung von Erklärungsmodellen zur Prognose treffen zu können, müsste man wiederholt Prognosen in die Zukunft mit immer wieder aktualisierten Modellen erstellen und deren Genauigkeit messen. Dies ändert aber nichts an einer der wichtigsten Quelle von Prognosefehlern, nämlich der Variabilität der saisonalen Abweichungen, die offenbar hauptsächlich auf die ~~jeweile~~ herrschenden Witterungsbedingungen zurückzuführen sind; mit dieser Variabilität ist zu rechnen, und sie wird sich auf die Prognoseergebnisse auswirken, unabhängig davon, welches Modell zur Prognose verwendet wird.

Die Anwendung von Saisonbereinigungsmodellen auf regionaler Ebene (Bundesländer) und die Aggregation ihrer Fehler zeigte, dass diese etwa gleich groß sind <sup>wie</sup> als jene desselben Modells für Österreich insgesamt. Regionale Milchanlieferungen könnten darüber Aufschluss geben, ob es regionale Unterschiede hinsichtlich der Ausschöpfung der "regionalen" Milchrichtmengen

gibt. Aber es gibt keine regionalen Quoten, wenn man von der regionalen Verteilung der Einzelmengen absieht, und daher hat es keinen Sinn, dieser Frage nachzugehen.

## Summary

The aim of this study was to propose and test methods which may be used to establish whether milk producers are in the process of delivering about as much milk to dairies as warranted by the national quota for milk deliveries which applies in the current dairy year or by how much these deliveries are going to miss the national quota. If it were possible to determine early with sufficient accuracy that an undersupply (or overshooting) of the quota is about to occur it would be possible to alert milk producers during the dairy year to deliver more (or less) milk and thus to ensure that they fill the quota and secure the corresponding revenues or that they avoid to pay a penalty in the form of a super levy, respectively.

A precondition for being able to issue a recommendation along these lines is the knowledge of the seasonal variation of milk deliveries. The analyses in this study show

- how the seasonal distribution of milk deliveries can be estimated,
- that this can as well be done by a simple seasonal adjustment method,
- that seasonal deviations have been very volatile, particularly those in June,
- how seasonal coefficients can be used to forecast milk deliveries in the whole dairy year,
- that using the coefficients of the seasonal adjustment model may produce biased forecasts since they may allocate too great a share of deliveries to April through September, and
- what accuracy is to be expected for different forecasting horizons if forecasts are based on the seasonal distribution methodology only, using seasonal adjustment models with and without an autoregressive error term.

Causal models produce more accurate forecasts in the reference period but proved not to be superior with respect to ex ante forecasts for the second half of 1998. In fact, forecasts up to three months ahead were on average more on target if done with the seasonal adjustment model with autoregressive errors. However, these short-term forecasts fluctuated widely independently of the model used. Thus the evidence so far lends no case for using the much more complicated causal models which require sophisticated technical skills and are time-consuming to implement and to update. A final verdict would necessitate an evaluation of repeated ex ante forecasts with repeatedly updated models. But the major cause of forecasting errors is the volatility of seasonal deviations which seem to be mainly due to wheather patterns; they are thus not likely to go away, and they are going to affect all forecasts irrespective of the type of model used for prediction.

The application of seasonal adjustment models for regions (federal states) and the aggregation of their errors does not produce more accurate results than a seasonal adjustment model for Austria as a whole. Saisonal data on deliveries by region could be used to estimate whether there are differences in the rate in which „regional“ quotas are filled; but regional quotas do not exist except in the form of a regional distribution of the national quota. Given that, there seems to be no merit in analysing regional milk delivery data.



## 9. Literaturverzeichnis

### *AGRARMARKT AUSTRIA:*

Tätigkeitsbericht ...  
 Wien (jährlich ab 1996)  
 Tätigkeitsbericht für Milch  
 Wien (jährlich bis 1995)  
 Förderungsdaten für das Jahr 1995  
 Wien 1994  
 Marktbericht Milch und Milchprodukte  
 Wien (monatlich)

### *ASSENMACHER, W.:*

Einführung in die Ökonometrie. 5. Auflage.  
 R. Oldenbourg Verlag, München Wien 1995.

### *BURREL, A.:*

Producer response to the EC milk superlevy.  
 In: European Review of Agricultural Economics 1990/1, 43-56

### *FESL, J.:*

Die Milchwirtschaft in Österreich.  
 In: Schriftenreihe Nr. 34 der Bundesanstalt für Agrarwirtschaft. Österr. Agrarverlag, Wien 1980.

### *GALLETO, L.:*

Il premio per la riduzione della produzione nell'ambito della politica del settore lattiero-caseario in Austria.  
 In: Rivista di Politica Agraria 13 (1995) 4, 3-12.

### *GOLDBERGER, A. S.:*

Econometric theory.  
 Wiley, New York 1964.

### *GREENE, W. H.:*

Econometric analysis. 2<sup>nd</sup> ed.  
 Macmillan, New York 1993.

### *JOHNSTON, J.:*

Econometric methods, 3<sup>rd</sup> ed.  
 McGraw-Hill, New York 1984.

### *JUMAH, A. und K. STEHLIK:*

Entwicklung der Preise bei tierischen Produkten und mögliche langfristige Zusammenhänge.  
 In: Der Förderungsdienst 42 (1994) 6, 183-184.

### *LINDER, S. und K. STEHLIK:*

Der europäische Markt für Milch und Milchprodukte.  
 Der Förderungsdienst 42 (1994) 6, 170-175.

**MENDENHALL, W. und R. L. SCHEAFFER:**

Mathematical statistics and applications.  
Duxbury, North Scituate (Mass.) 1973.

**MILCHWIRTSCHAFTSFOND:**

Tätigkeitsbericht des MWF über das Jahr ...  
Wien (jährlich)

**NERLOVE, M., D. M. GRETHER und J. L. CARVALHO:**

Analysis of economic time series - a synthesis.  
Academic Press, London 1979.

**ORTNER, K. M.:**

Kurzfristige Prognosen der Milchlieferung in Österreich mit einem kausalen Modell.  
In: Die Bodenkultur 35 (1984) 2, 181-195.

Die Milchlieferung in Österreich und ihre Prognose.  
In: Monatsberichte über die österreichische Landwirtschaft 31 (1984) 8, 526-532.

Auswirkungen von Maßnahmen zur Verminderung der Milchlieferung in Österreich.  
In: Die Bodenkultur 38 (1987) 4, 377-388.

An outline of the milk quota policy in Austria.  
In: KETTUNEN, L. (ed.), Supply management by government in agriculture. Vauk, Kiel 1987, 69-75.

**WÖRGÖTTER, A.:**

Auswirkungen der Milchkontingentierung auf die Milchliefereien. Interventionsanalyse mit Methoden der modernen Zeitreihenanalyse.  
Institut für Höhere Studien, Wien 1990.

**WÜGER, M.:**

Das neue Saisonbereinigungsverfahren des WIFO.  
In: Monatsberichte des Österreichischen Instituts für Wirtschaftsforschung 68 (1995) 10, 625-635.



10. Anhang

Tabelle A1: Regressionskoeffizienten des Saisonbereinigungsmodells

Dependent Variable S - Estimation by Least Squares			
Monthly Data From 1979:01 To 1998:06			
Usable Observations	221	Degrees of Freedom	202
Total Observations	234	Skipped/Missing	13
Centered R**2	0.889773	R Bar **2	0.879951
Uncentered R**2	0.889961	T x R**2	196.681
Mean of Dependent Variable	0.0030410519		
Std Error of Dependent Variable	0.0737316721		
start eloop estep ie end ed			
55 235 12 246 246 246			
Standard Error of Estimate	0.0255466524		
Sum of Squared Residuals	0.1318315528		
Durbin-Watson Statistic	0.539235		
Q(36-0)	477.300759		
Significance Level of Q	0.00000000		

Variable	Coeff	Std Error	T-Stat	Signif
*****				
1. JAN	-0.021282107	0.010498792	-2.02710	0.04396615
2. FEB	-0.105704678	0.005913584	-17.87489	0.00000000
3. MAE	0.020435889	0.005901002	3.46312	0.00065176
4. APR	0.016853303	0.005860804	2.87560	0.00446500
5. MAI	0.115929341	0.009584094	12.09601	0.00000000
6. JUN	0.017613147	0.009526739	1.84881	0.06594643
7. JUL	0.074137755	0.009740115	7.61159	0.00000000
8. AUG	0.047988495	0.006021404	7.96965	0.00000000
9. OKT	0.006199318	0.006021404	1.02955	0.30445388
10. NOV	-0.095617212	0.010249367	-9.32908	0.00000000
11. DEZ	-0.061412860	0.010374479	-5.91961	0.00000001
12. JANT	-0.848644453	0.823163001	-1.03096	0.30379447
13. MAIT	0.914465940	0.598999569	1.52666	0.12841096
14. JUNT	3.296180541	0.627327293	5.25432	0.00000038
15. JULT	0.849726100	0.661569900	1.28441	0.20047007
16. NOV T	-1.065290953	0.768826287	-1.38561	0.16739494
17. DEZ T	-0.837778388	0.795931735	-1.05258	0.29379298
18. BMAP	-1.083770600	0.664842931	-1.63012	0.10463544
19. BAPP	-1.018843795	0.729068428	-1.39746	0.16380831

Neu<sup>30</sup>:

Dependent Variable S - Estimation by Hildreth-Lu

Monthly Data From 1979:02 To 1998:06

Usable Observations	221	Degrees of Freedom	207
Total Observations	233	Skipped/Missing	12
Centered R**2	0.480025	R Bar **2	0.447369
Uncentered R**2	0.480912	T x R**2	106.281
Mean of Dependent Variable	0.0030410519		
Std Error of Dependent Variable	0.0737316721		
Standard Error of Estimate	0.0548114944		
Sum of Squared Residuals	0.6218900821		
Durbin-Watson Statistic	1.082303		
Q(36-1)	4.359373		
Significance Level of Q	1.00000000		

Variable	Coeff	Std Error	T-Stat	Signif
*****				
1. JAN	-0.030071238	0.018395687	-1.63469	0.10363395
2. FEB	-0.106902519	0.018756739	-5.69942	0.00000004
3. MAE	0.019981837	0.018680541	1.06966	0.28601786
4. APR	0.016694822	0.018424377	0.90613	0.36592225
5. MAI	0.121835881	0.018022867	6.76007	0.00000000
6. JUN	0.024641337	0.021675157	1.13685	0.25691657
7. JUL	0.085611256	0.015965347	5.36232	0.00000022
8. AUG	0.048987224	0.012872293	3.80563	0.00018624
9. OKT	0.006517668	0.012914431	0.50468	0.61431973
10. NOV	-0.106888182	0.016112649	-6.63381	0.00000000
11. DEZ	-0.070161908	0.017631454	-3.97936	0.00009557
12. JUNT	2.524329115	1.083735845	2.32928	0.02080816
13. BMAP	-0.762834272	1.144909096	-0.66628	0.50597166
*****				
14. RHO	0.747449405	0.148198159	5.04358	0.00000100

<sup>30</sup> Die Maximum Likelihood Grid Search Methode garantiert - im Gegensatz zur Cochrane-Orcutt-Transformation der Variablen - das Erreichen eines globalen Minimums der Fehlervarianz (JOHNSTON 1984, S. 366).

**Tabelle A2      Regressionskoeffizienten des kausalen Modells**

Dependent Variable LMIL - Estimation by Least Squares

Monthly Data From 1979:01 To 1998:06

Usable Observations	201	Degrees of Freedom	170
Total Observations	234	Skipped/Missing	33
Centered R**2	0.948048	R Bar **2	0.938881
Uncentered R**2	0.999988	T x R**2	200.998
Mean of Dependent Variable	5.2531645569		
Std Error of Dependent Variable	0.0798372071		
Standard Error of Estimate	0.0197376298		
Sum of Squared Residuals	0.0662275854		
Regression F(30,170)	103.4094		
Significance Level of F	0.00000000		
Durbin-Watson Statistic	1.204644		
Q(36-0)	251.540937		
Significance Level of Q	0.00000000		

Variable	Coeff	Std Error	T-Stat	Signif
*****				
1. JAN	0.776664082	0.924072081	0.84048	0.40181988
2. FEB	0.699982075	0.923304447	0.75813	0.44942462
3. MAE	0.824471180	0.923555479	0.89271	0.37327212
4. APR	0.827557234	0.922781567	0.89681	0.37108998
5. MAI	0.929385075	0.923041357	1.00687	0.31542697
6. JUN	0.848493128	0.922805583	0.91947	0.35915199
7. JUL	0.897164552	0.922512116	0.97252	0.33217200
8. AUG	0.862385027	0.922238933	0.93510	0.35106348
9. SEP	0.813575553	0.922590486	0.88184	0.37910944
10. OKT	0.822314132	0.922692098	0.89121	0.37407514
11. NOV	0.712433606	0.922842357	0.77200	0.44118673
12. DEZ	0.746463969	0.923561875	0.80824	0.42007933
13. LRMIP{8}	0.113774919	0.051878276	2.19311	0.02965702
14. LRMIP{21}	0.141331185	0.049991929	2.82708	0.00526135
15. LRMIP{24}	0.209198997	0.081167629	2.57737	0.01080410
16. LRMIP{33}	0.086294094	0.057190442	1.50889	0.13318314
17. LRKAP	0.122133920	0.049958722	2.44470	0.01551800
18. LRSWP{17}	-0.072904759	0.030697023	-2.37498	0.01866414
19. LRSWP{33}	-0.071124649	0.030959539	-2.29734	0.02281829
20. RRPR	0.000060753	0.000014738	4.12208	0.00005858
21. RRPR{13}	0.000029972	0.000012413	2.41456	0.01681496
22. ERM{8}	0.000437076	0.000092783	4.71072	0.00000511
23. DQU	-0.000275167	0.000147390	-1.86693	0.06363261
24. DQU{3}	-0.000166971	0.000108066	-1.54508	0.12418711
25. DQU{21}	0.000757559	0.000152147	4.97913	0.00000156
26. AST	0.076287881	0.030172609	2.52838	0.01236982
27. AST{9}	0.109130914	0.030554146	3.57172	0.00046146
28. AST{19}	0.033961470	0.030954599	1.09714	0.27413265
29. AST{21}	0.093544164	0.037513727	2.49360	0.01360159
30. RKF{11}	-0.000219927	0.000096175	-2.28675	0.02344386
31. FLV	-0.000494561	0.000104097	-4.75095	0.00000429

Neu:

Dependent Variable LMIL - Estimation by Hildreth-Lu

Monthly Data From 1979:02 To 1998:06

Usable Observations	213	Degrees of Freedom	191
Total Observations	233	Skipped/Missing	20
Centered R**2	0.749001	R Bar **2	0.721404
Uncentered R**2	0.999940	T x R**2	212.987
Mean of Dependent Variable	5.2531703468		
Std Error of Dependent Variable	0.0813217561		
Standard Error of Estimate	0.0429233730		
Sum of Squared Residuals	0.3519014468		
Durbin-Watson Statistic	1.246854		
Q(36-1)	7.404308		
Significance Level of Q	0.99999982		

Variable	Coeff	Std Error	T-Stat	Signif
*****				
1. JAN	3.880205783	0.987979206	3.92742	0.00011986
2. FEB	3.800299238	0.989018651	3.84250	0.00016569
3. MAE	3.925951410	0.989076380	3.96931	0.00010197
4. APR	3.925047840	0.987287254	3.97559	0.00009951
5. MAI	4.029735343	0.987152381	4.08218	0.00006554
6. JUN	3.953891218	0.987820313	4.00264	0.00008958
7. JUL	3.997335194	0.988252504	4.04485	0.00007593
8. AUG	3.960642422	0.988535338	4.00658	0.00008821
9. SEP	3.912709686	0.988563320	3.95798	0.00010654
10. OKT	3.922458524	0.986561312	3.97589	0.00009940
11. NOV	3.810394211	0.985680666	3.86575	0.00015171
12. DEZ	3.845737478	0.987004776	3.89637	0.00013501
13. LRMIP{21}	0.138885609	0.129874675	1.06938	0.28624727
14. RRPR	0.000033447	0.000027880	1.19967	0.23175414
15. RRPR{13}	0.000030585	0.000034992	0.87406	0.38318201
16. ERM{8}	0.000195563	0.000165517	1.18153	0.23886177
17. DQU{3}	-0.000296832	0.000256047	-1.15928	0.24778760
18. DQU{21}	0.000314734	0.000250542	1.25621	0.21057358
19. AST{9}	0.117357273	0.064266015	1.82612	0.06939397
20. AST{21}	0.120941254	0.063130321	1.91574	0.05689176
21. FLV	-0.000248808	0.000163242	-1.52417	0.12912051
*****				
22. RHO	0.535703840	0.146292645	3.66186	0.00032409

**Tabelle A3      Regressionskoeffizienten des partiellen Anpassungsmodells**

Dependent Variable LMIL - Estimation by Least Squares

Monthly Data From 1979:01 To 1998:06

Usable Observations	198	Degrees of Freedom	169
Total Observations	234	Skipped/Missing	36
Centered R**2	0.952170	R Bar **2	0.944246
Uncentered R**2	0.999989	T x R**2	197.998
Mean of Dependent Variable	5.2541138672		
Std Error of Dependent Variable	0.0798711589		
Standard Error of Estimate	0.0188594014		
Sum of Squared Residuals	0.0601094165		
Regression F(28,169)	120.1564		
Significance Level of F	0.00000000		
Durbin-Watson Statistic	1.065727		
Q(36-0)	363.063545		
Significance Level of Q	0.00000000		

Variable	Coeff	Std Error	T-Stat	Signif
*****				
1. JAN	1.241076213	0.584808362	2.12219	0.03527866
2. FEB	1.163805695	0.584768274	1.99020	0.04818139
3. MAE	1.289331861	0.584602881	2.20548	0.02876976
4. APR	1.283447275	0.584874714	2.19440	0.02957106
5. MAI	1.383428995	0.585177412	2.36412	0.01920856
6. JUN	1.260959316	0.585485146	2.15370	0.03268080
7. JUL	1.353602975	0.584929365	2.31413	0.02186406
8. AUG	1.318928206	0.584879501	2.25504	0.02541410
9. SEP	1.272158065	0.584736058	2.17561	0.03097313
10. OKT	1.282144212	0.584655935	2.19299	0.02967417
11. NOV	1.169186005	0.584697982	1.99964	0.04714121
12. DEZ	1.205513078	0.584694806	2.06178	0.04075955
13. JUNT	5.151506654	1.066412731	4.83069	0.00000303
14. LRMIP{6}	0.235557827	0.050557112	4.65924	0.00000640
15. LRMIP{10}	0.096856292	0.057436961	1.68631	0.09358207
16. LRMIP{20}	0.216844059	0.051704399	4.19392	0.00004416
17. LRMIP{36}	0.058167318	0.040679129	1.42991	0.15459018
18. RRPR	0.000057781	0.000011939	4.83979	0.00000291
19. ERM{10}	0.000106332	0.000087691	1.21258	0.22698300
20. DQU	-0.000285857	0.000136427	-2.09532	0.03763298
21. FLV	-0.000510645	0.000096830	-5.27362	0.00000040
22. FLV{8}	-0.000100847	0.000073309	-1.37564	0.17075336
23. LSRSWP{2}	-0.063550338	0.038688785	-1.64260	0.10232433
24. SAST{4}	0.164096684	0.035023692	4.68531	0.00000572
25. SAST{12}	0.074417584	0.042475605	1.75201	0.08158629
26. SAST{17}	0.193086758	0.042010779	4.59612	0.00000839
27. SRKF{9}	-0.000785999	0.000127442	-6.16749	0.00000000
28. SFLV{12}	-0.000708047	0.000116509	-6.07717	0.00000001
29. LSRRPR{21}	0.049682125	0.007739285	6.41947	0.00000000

## Neu

Dependent Variable LMI<sub>L</sub> - Estimation by Hildreth-Lu

Monthly Data From 1979:02 To 1998:06

Usable Observations	198	Degrees of Freedom	168
Total Observations	233	Skipped/Missing	35
Centered R**2	0.724795	R Bar **2	0.677289
Uncentered R**2	0.999937	T x R**2	197.987
Mean of Dependent Variable	5.2541138672		
Std Error of Dependent Variable	0.0798711589		
Standard Error of Estimate	0.0453729318		
Sum of Squared Residuals	0.3458620943		
Durbin-Watson Statistic	1.068576		
Q(36-1)	6.471074		
Significance Level of Q	0.99999997		

Variable	Coeff	Std Error	T-Stat	Signif
*****				
1. JAN	1.919733729	2.091634178	0.91782	0.36003136
2. FEB	1.842077775	2.091688595	0.88067	0.37975706
3. MAE	1.966253896	2.091471668	0.94013	0.34850099
4. APR	1.960890722	2.092178204	0.93725	0.34997619
5. MAI	2.060971225	2.093393875	0.98451	0.32627961
6. JUN	1.945989456	2.093831895	0.92939	0.35401973
7. JUL	2.033351033	2.092030872	0.97195	0.33247235
8. AUG	1.997995419	2.091873878	0.95512	0.34088816
9. SEP	1.949418312	2.091485437	0.93207	0.35263605
10. OKT	1.958686342	2.091285953	0.93659	0.35031174
11. NOV	1.845979104	2.091471375	0.88262	0.37870159
12. DEZ	1.882028271	2.091318671	0.89992	0.36944873
13. JUNT	4.351675466	2.162951146	2.01192	0.04582686
14. LRMIP{6}	0.256471807	0.161725113	1.58585	0.11465375
15. LRMIP{10}	0.063429257	0.168324542	0.37683	0.70677760
16. LRMIP{20}	0.117410995	0.168198750	0.69805	0.48611150
17. LRMIP{36}	0.065580068	0.142097112	0.46152	0.64502556
18. RRPR	0.000048390	0.000039842	1.21455	0.22624380
19. ERM{10}	0.000124655	0.000348246	0.35795	0.72082875
20. DQU	-0.000245279	0.000461345	-0.53166	0.59566327
21. FLV	-0.000370080	0.000385024	-0.96119	0.33783882
22. FLV{8}	-0.000111147	0.000240301	-0.46253	0.64429689
23. LSRSWP{2}	-0.090686287	0.160715374	-0.56427	0.57332539
24. SAST{4}	0.168204994	0.164648507	1.02160	0.30843888
25. SAST{12}	0.100694595	0.201750942	0.49910	0.61835942
26. SAST{17}	0.199435648	0.213905978	0.93235	0.35249266
27. SRKF{9}	-0.000655452	0.000574387	-1.14113	0.25543832
28. SFLV{12}	-0.000600746	0.000456348	-1.31642	0.18982542
29. LSRRPR{21}	0.045736203	0.033792537	1.35344	0.17773302
*****				
30. RHO	0.547469405	0.193632134	2.82737	0.00526372



**Tabelle A4      Berechnung der Superabgabe für 1997/98**

Überlieferung	1.000 t	Fettgehalt
Milchgarantiemenge	2.383,2	3,03%
Fettkorrektur	-4,3	
korr. Milchgarantiemenge + umgewandelte D-Quoten	2.378,9 33,0	3,04%
Referenzmenge	2.411,9	
Anlieferungsmenge	2.448,1	
Netto-Überlieferung	36,2	
Brutto-Überlieferungen	132,3	
Superabgabe		Lw. U.-Kurs
ECU/kg Nettoüberlieferung	0,3563	13,9489
Betrag in Mio. ECU	12,9	
Betrag in Mio. ATS	180	
S/kg Bruttoüberlieferung	1,36	
Quelle: Landwirtschaftliches Wochenblatt v. 17.7.1998; eigene Berechnungen		

**Tabelle A5      Berechnung der Superabgabe für 1998/99**

Überlieferung	1.000 t	Fettgehalt
Milchgarantiemenge	2.393,979	4,03
+ umgewandelte D-Quoten	41,872	
Referenzmenge	2.435,851	
Anlieferungsmenge	2.493,907	4,14
fettkorrigiert	2.543,286	4,03
Faktor	1,0198	
Netto-Überlieferung	107,435	
Brutto-Überlieferungen	185,005	
Superabgabe		Wechselkurs
Euro/kg Nettoüberlieferung	0,3563	13,7603
Betrag in Mio. Euro	38,3	
Betrag in Mio. ATS	527	
S/kg Bruttoüberlieferung	2,85	
Quelle: Landwirtschaftliches Wochenblatt v. 26.6.1999; eigene Berechnungen		

