

# Wie viel bringt eine verbesserte Produktionsprogrammplanung auf der Grundlage einer systematischen Auswertung empirischer Zeitreihen?

– Die Bedeutung von Prognosemodellen bei der Optimierung unter Unsicherheit –

## What benefits can be derived from systematic statistical analyses of empirical data and improved production program planning approaches?

– The role of time series models in stochastic optimisation –

Oliver Mußhoff und Norbert Hirschauer  
Humboldt-Universität zu Berlin

### Zusammenfassung

In diesem Beitrag wird das Verbesserungspotenzial von Optimierungsverfahren im Vergleich zu empirisch beobachtbaren Programm-scheidungen der landwirtschaftlichen Unternehmenspraxis im Rahmen einer Fallstudie untersucht. Dazu werden für vier ausgewählte Brandenburger Marktfruchtbetriebe - ausgehend vom Informationsstand der Landwirte zum jeweiligen Planungszeitpunkt - modellgestützt optimierte Alternativprogramme für insgesamt sechs Planzieljahre aufgestellt. In der normativen Optimierungsrechnung wird die Gesamtdeckungsbeitragsvarianz des tatsächlichen Programms, die implizit die subjektive Risikoeinstellung des jeweiligen Landwirts widerspiegelt, als Restriktion (Obergrenze) berücksichtigt. Gleichzeitig wird die Unsicherheit hinsichtlich der zu erzielenden Deckungsbeiträge über eine systematische statistische Auswertung der vorhandenen empirischen Daten (Einzeldeckungsbeitragszeitreihen) erfasst und bei der Optimierung berücksichtigt. Die Datenauswertung und damit die Schaffung der Informationsgrundlage für dieses risikobehaftete Planungsproblem erfolgt in drei verschiedenen Varianten, nämlich über (1) einfache Schätzungen statischer Verteilungen, (2) systematische Zeitreihenanalysen unter der Annahme linearer stochastischer Prozesse und (3) ergebnisoffene Zeitreihenanalysen, die auch nichtlineare stochastische Prozesse als Ergebnis zulassen. Diese drei Varianten unterscheiden sich sowohl hinsichtlich der methodischen Anforderungen als auch der Qualität der Datenauswertung.

Der Vergleich empirischer und normativer Ergebnisse ergibt in Abhängigkeit von der Qualität der Datenauswertung ein differenziertes Bild: Berücksichtigt man das Risiko lediglich über einfache Verteilungen, so haben die modellgestützt optimierten Alternativprogramme kein Verbesserungspotenzial gegenüber den von den Landwirten tatsächlich getroffenen Anbauentscheidungen. Dies scheint zunächst die Ablehnung formaler Optimierungsmodelle durch die landwirtschaftliche Unternehmenspraxis zu bestätigen. Dies ändert sich allerdings grundlegend, wenn man nicht einfach a priori eine statische Verteilung unterstellt, sondern eine explizite Zeitreihenanalyse der empirischen Beobachtungswerte durchführt. Bei Zugrundelegung der damit verbesserten Informationsbasis wären im Durchschnitt der zurückliegenden sechs Jahre die Gesamtdeckungsbeiträge, die durch eine Planung mit Hilfe eines formalen Optimierungsverfahrens hätten erzielt werden können, *deutlich* besser ausgefallen.

### Schlüsselwörter

Produktionsprogrammplanung; Optimierung; Unsicherheit; statische Verteilungsannahmen; stochastische Prozesse

### Abstract

In this paper we examine whether there is room for improvement in farm program decisions through the integration of formal mathematical optimisation into the planning process. Probing the potential for improvement, we investigate the cases of four Brandenburg cash crop farms over the last six years. We find that their total gross margins could have been increased significantly through a more sophisticated program planning. However, we also find that the superiority of formalised planning approaches depends on the quality of the data.

The superior formal planning approach includes, in contrast to farmers' ad hoc planning, a systematic time series analysis of gross margins and a stochastic optimisation model. For each of the six years, the formal planning approach provides optimised alternative programs based on the information available to the farmers at the respective time of planning. In order to avoid solutions that exceed the farmers' risk tolerance, the variance of the observed program's total gross margin which implicitly reflects the risk attitude of the individual farmer is used as an upper bound in the optimisation. Using the yields and prices realised at the end of each planning period, the total gross margins that could have been realised through the formally optimised programs in each year are then compared to those that were actually realised.

### Key words

planning of the production program; optimisation; uncertainty; static distributions; stochastic processes

## 1. Einleitung

Optimierungsverfahren (lineare oder quadratische Programmierung) finden bereits seit mehreren Jahrzehnten in der agrarökonomischen Forschung und Lehre starke Beachtung (vgl. z.B. BRANDES, 1974; DENT et al., 1986; HAZELL und NORTON, 1986; HARDAKER et al., 2004). Allerdings werden sie in der neueren agrarökonomischen Literatur kaum noch für den Einsatz als betriebliches Planungsinstrument behandelt. So wurden bspw. in der „Agrarwirtschaft“ in den letzten zehn Jahren weniger als zehn Beiträge veröffentlicht, die im weitesten Sinne diesem Bereich zuzuordnen sind. Dies mag unter anderem darin begründet sein, dass Optimierungsverfahren im Agrarbereich - bis auf die Bestimmung kostenminimaler Mischungen in der Futter-

mittelindustrie - kaum Eingang in einzelbetriebliche Planungsprozesse gefunden haben. So zeigt bspw. eine empirische Erhebung von BOKELMANN et al. (1996), dass die Beratung in lediglich 5 % von insgesamt 140 befragten landwirtschaftlichen Betrieben in Brandenburg durch die lineare Optimierung unterstützt wird. HANF (1991) wirft in Bezug auf die lineare Optimierung sogar die Frage auf, ob wertvolle Ausbildungszeit an Universitäten vergeudet wird.

Insbesondere mit Blick auf die Bestimmung des Produktionsprogramms wird vielfach argumentiert, dass Landwirte basierend auf Intuition und Erfahrung optimal entscheiden, ohne in der Lage sein zu müssen, Planannahmen, wie z.B. differenzierte Fruchtfolgerestriktionen, explizit quantifizieren zu können. Ohne explizite Definition des Sets von zulässigen Lösungen ist aber eine quantitative Planung im Rahmen einer Optimierung nicht möglich. Gleiches gilt auf der Zielebene für die subjektive Risikoeinstellung der einzelnen Landwirte, die ebenfalls nur schwer zu quantifizieren ist. Ohne Bestimmung der individuellen Zielfunktion ist keine entscheidungsträgerspezifische Optimierung des Produktionsprogramms möglich, zumal die Modellergebnisse in außerordentlich starkem Maße von der individuellen Risikoeinstellung beeinflusst werden. Deshalb liefern bislang vorgeschlagene Ansätze zur Optimierung unter Unsicherheit in aller Regel nicht eine Optimallösung, sondern - als Ergebnis von Variantenrechnungen - mehrere sog. *risikoeffiziente* Kombinationen von Erwartungswert des Gesamtdeckungsbeitrages und Risiko. Mangels Verfügbarkeit bzw. adäquater Auswertung quantitativer Daten, die sowohl die Restriktionen als auch die Zielfunktion des einzelnen Entscheidungsträgers realistisch widerspiegeln, werden Optimierungsmodelle kaum für die praktische Entscheidungsunterstützung in landwirtschaftlichen Unternehmen eingesetzt. In aller Regel werden sie vielmehr lediglich dazu genutzt, durchschnittlich zu erwartende Handlungen und Anpassungsreaktionen „am Schreibtisch“ näherungsweise nachzustellen.

Das Ziel dieses Beitrages besteht darin, das Verbesserungspotenzial des gezielten Einsatzes formaler Optimierungsverfahren gegenüber „intuitiv“ getroffenen Programm Entscheidungen der landwirtschaftlichen Unternehmenspraxis zu eruieren. Dazu wird das wirtschaftliche Ergebnis, das mit normativ bestimmten (optimierten) Produktionsprogrammen hätte erzielt werden können, mit den Ergebnissen empirisch beobachteter Programme landwirtschaftlicher Unternehmen verglichen. Dieser Leistungsvergleich erfolgt für vier Betriebe über jeweils sechs zurückliegende Jahre und weist bei der Erfassung und der Berücksichtigung des Risikos sowie der Risikoeinstellung folgende Besonderheiten auf:

a) Die Unsicherheit hinsichtlich der zu erzielenden Deckungsbeiträge wird über die Auswertung der vorhandenen empirischen Betriebsdaten (Einzeldeckungsbeitragsreihen) erfasst. Diese Datenauswertung liefert *Prognosemodelle*, die die Informationsgrundlage für dieses risikobehaftete Planungsproblem darstellen. Drei verschiedene Varianten von Prognosemodellen werden getestet: (1) einfache Schätzung statischer Verteilungen, (2) systematische Zeitreihenanalysen unter der Annahme linearer stochastischer Prozesse und (3) ergebnisoffene Zeitreihenanalysen, die auch nichtlineare stochastische Prozesse als Ergebnis zulassen.

b) Die subjektive Risikoeinstellung, die *implizit* in dem vom jeweiligen Landwirt selbst gewählten Produktionsprogramm zum Ausdruck kommt, wird über die von ihm akzeptierte Gesamtdeckungsbeitragsvarianz seines eigenen Programms quantifiziert und *explizit* als Restriktion in das jeweilige Optimierungsmodell aufgenommen.

c) Zu jedem Planungszeitpunkt und für jeden Betrieb werden in Abhängigkeit von der Datenauswertung (vgl. a.) drei verschiedene Planungsvarianten erstellt. Das formale Optimierungsmodell maximiert den erwarteten Gesamtdeckungsbeitrag unter Berücksichtigung der betrieblichen Restriktionen inklusive der jeweils maximal zulässigen Varianz (vgl. b.). Dies erlaubt es, das Verbesserungspotenzial der jeweiligen Planungsvariante im Vergleich zu den empirischen Programmen zu bestimmen.

Es ist bereits intuitiv leicht einsichtig, dass eine einfache Schätzung einer statischen Verteilung bzw. der Rückgriff auf Mittelwert und Varianz gleichgewichteter zurückliegender Beobachtungswerte keine gute Prognose für zukünftige Beobachtungswerte darstellen kann, wenn die Zeitreihe bspw. einen Trend aufweist. Dennoch stellt dies die implizite Vorgehensweise einer Vielzahl von Konzepten zur Berücksichtigung des Risikos in der landwirtschaftlichen Planung dar. Bei den auf HAZELL (1971) aufbauenden Modellen der Minimization-Of-Total-Absolute-Deviation (MOTAD) wird zwar keine parametrische Verteilung geschätzt, aber die historische Verteilung genutzt. Dennoch erfolgt methodenimmanent eine Gleichgewichtung vergangener Werte. Eine gleichfalls methodisch zwingende Gleichgewichtung erfolgt auch bei der Maximierung des Sicherheitsäquivalents im Rahmen von Erwartungswert-Varianz- oder EV-Modellen (vgl. z.B. ROBISON und BARRY, 1987). Hier wird - in aller Regel ohne statistische Überprüfung - eine Festlegung auf multivariat normalverteilte Zufallsvariablen (hier: Deckungsbeiträge der einzelnen Produktionsverfahren) vorgenommen (vgl. z.B. HAZELL und NORTON, 1986). Bei unterschiedlichen Verteilungen (insbesondere mit höheren Momenten) lässt sich nämlich die Varianz des Gesamtdeckungsbeitrages faktisch nicht mehr analytisch aus den Einzelvarianzen herleiten (vgl. DOPPLER und MÄRZ, 1989).

Stochastische Prozesse spiegeln demgegenüber das zeitliche Entwicklungsmuster unsicherer Größen wider und spezifizieren explizit deren erwartete Verteilung zu einzelnen Zeitpunkten. MUBHOFF und HIRSCHAUER (2004) haben in einem jüngst in der „Agrarwirtschaft“ erschienenen Beitrag im Rahmen eines Methodenvergleichs verdeutlicht, dass ein adäquates statistisches Prognosemodell über die explizite Ableitung des „geeigneten“ stochastischen Prozesses aus dem vorhandenen Datenmaterial auch bei einer Periode (und damit auch bei der Programmplanung) maßgeblich für die Planungsergebnisse ist. In dem hier vorliegenden Beitrag wird nun gezeigt, welche Bedeutung der Schaffung und Berücksichtigung einer „möglichst guten“ Informationsgrundlage zukommt, damit formale Optimierungsmodelle tatsächlich eine Verbesserung der Planung bewirken können. Dies ist von großer Bedeutung, da ein komplexes formales Planungsmodell, das modellbedingt nur mit bestimmten Informationen „gefüttert“ werden kann, auch eine Verschlechterung der Planung gegenüber nicht formalisierten Vorgehensweisen mit sich bringen kann.

## 2. Methodische Vorgehensweise

Im Folgenden wird die methodische Vorgehensweise zur Bestimmung der optimierten Produktionsprogramme detailliert dargelegt. Zunächst wird gezeigt, wie die Unsicherheit hinsichtlich der betrieblichen Einzeldeckungsbeiträge quantifiziert wird. Dazu werden auf der Grundlage der betriebsindividuellen Zeitreihen, die bis zum jeweiligen Planungszeitpunkt vorliegen, Prognosemodelle, d.h. Verteilungen bzw. stochastische Prozesse identifiziert (Punkt 2.1). In einem zweiten Schritt wird dargelegt, wie die betrieblichen Restriktionen im jeweiligen Planungszeitpunkt erhoben werden. Dies schließt die maximal zulässige Varianz mit ein (Punkt 2.2). Anschließend wird erläutert, wie unter Berücksichtigung der jeweiligen Prognosemodelle und der Restriktionen für jeden Entscheidungszeitpunkt und jeden Betrieb modellgestützte (optimierte) Alternativprogramme aufgestellt werden, deren „mögliche“ Leistungen mit den Gesamtdeckungsbeiträgen der Produktionsprogramme verglichen werden können, die von den Landwirten tatsächlich realisiert wurden (Punkt 2.3).

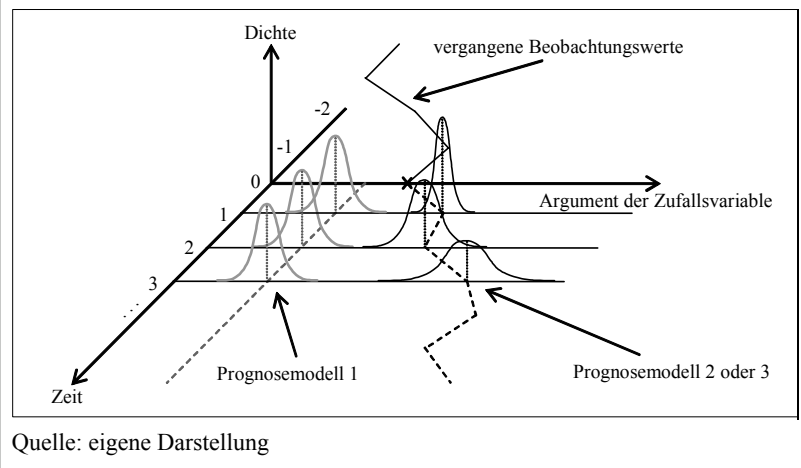
### 2.1 Berücksichtigung von Unsicherheit hinsichtlich der Einzeldeckungsbeiträge

Die Höhe der betrieblich erzielbaren Einzeldeckungsbeiträge ist mit Unsicherheit behaftet. Diese Unsicherheit wird berücksichtigt, indem Verteilungsinformationen aus den in der Vergangenheit beobachteten Realisationen der Zufallsvariable abgeleitet werden. Grundsätzlich sollten möglichst umfangreiche, für den einzelnen Betrieb gültige Datensätze verwendet werden. Aufgrund des wendebedingten Strukturbruchs Anfang der 90er Jahre wird für den Zeitraum von 1980 bis 1997 anstelle betriebsindividueller Daten ein Proxy verwendet. Dieses Proxy sind plausible standortangepasste Hilfszeitreihen, die unter Verwendung von ZMP-Angaben (verschiedene Jahrgänge) und Daten der LDS BRANDENBURG (2003) erstellt wurden. Konkret stammen die Daten von 1980 bis 1990 von der ZMP und von 1991 bis 1997 von der LDS Brandenburg. Die Daten von 1998 bis 2004 sind betriebsindividuelle Einzeldeckungsbeiträge.

Die jeweils analysierte Zeitreihe umfasst den Zeitraum  $t = 1980, 1981, \dots, t^* - 1$ . Dabei beschreibt  $t^* - 1$  den betrachteten Planungszeitpunkt, d.h. das Jahr 1998, 1999, 2000, 2001, 2002 bzw. 2003. Für das erste Planungsjahr 1998 steht also eine Zeitreihe mit 19 Daten zur Auswertung zur Verfügung. Für spätere Planungsjahre verlängert sich die auswertbare Zeitreihe um jeweils ein Jahr. Zu jedem der betrachteten sechs Planungszeitpunkte werden für jeden Betrieb und alle Einzeldeckungsbeiträge (1) einfache Schätzungen statischer Verteilungen, (2) Zeitreihenanalysen unter Annahme linearer stochastischer Prozesse und (3) ergebnisoffene Zeitreihenanalysen mittels „selbstorganisierender Modellgenerierung“ durchgeführt.

In Abbildung 1 wird der fundamentale Unterschied zwischen den beiden Arten der Datenauswertung und Prognosebildung grafisch verdeutlicht. Es wird gezeigt, welche Dichtefunktionen für den Einzeldeckungsbeitrag sich bei

Abbildung 1. Implizite Annahmen der unterschiedlichen Prognosemodelle (stilisiert)



Annahme einer statischen Verteilung (Prognosemodell 1) bzw. von stochastischen Prozessen (Prognosemodell 2 oder 3) für drei zukünftige Zeitpunkte ergeben könnten.

Die Annahme einer statischen Verteilung impliziert, dass für jeden zukünftigen Zeitpunkt die gleiche (zeitinvariante) Dichtefunktion gilt, deren Erwartungswert dem Mittelwert der vergangenen Beobachtungswerte entspricht. Bildlich gesprochen ist damit der gegenwärtig beobachtete Wert für die Zufallsvariable nicht notwendigerweise der Ausgangspunkt für die Berechnung des Erwartungswertes zu zukünftigen Zeitpunkten. Bei stochastischen Prozessen ist dagegen die (zeitvariable) Dichtefunktion der Zufallsvariable zu zukünftigen Zeitpunkten immer vom gegenwärtigen Beobachtungswert (und eventuell von weiter in der Vergangenheit liegenden Beobachtungswerten unterschiedlicher Gewichtung) abhängig. Gleichzeitig sind der Erwartungswert und die Standardabweichung der Zufallsvariable vom geschätzten stochastischen Prozess und vom Prognosezeitraum abhängig. Typischerweise steigt die Standardabweichung mit zunehmendem Prognosezeitraum an.

Für die in diesem Beitrag verfolgte Zielsetzung ist nur die Verteilung für einen zukünftigen Zeitpunkt von unmittelbarer Relevanz. Wie die Abbildung verdeutlicht, können sich aber auch schon dabei deutliche Unterschiede zwischen den beiden Arten der Datenauswertung und Prognosebildung ergeben.

#### 2.1.1 Prognosemodell 1: Statische Verteilungsannahmen

Mit Hilfe des MS-EXCEL Add-In BEST FIT wurde getestet, welche Annahme bezüglich der Verteilung für die Einzeldeckungsbeiträge zutreffend ist. Gemäß Chi-Quadrat-, Kolmogorov-Smirnov- und Anderson-Darling-Test kann für keine der betrachteten Einzeldeckungsbeitragszeitreihen die Normalverteilung auf einem Signifikanzniveau von 5 % abgelehnt werden. Allerdings weist die Beta-, die logistische und/oder die Dreiecksverteilung in Einzelfällen eine geringfügig bessere Anpassung an die empirische Verteilung auf als die Normalverteilung. Trotzdem wurde hier in Anlehnung an die Standardvorgehensweise (vgl. HAZELL und NORTON, 1986: 81ff.) für alle Einzeldeckungsbeiträge zunächst eine Normalverteilung unterstellt.

Kennzeichnet man die zu den Zeitpunkten  $t$  beobachteten Einzeldeckungsbeiträge des Produktionsverfahrens  $j$

( $j = 1, 2, \dots, J$ ) mit  $DB_t^j$ , so könnte man - in Anlehnung an die formale Darstellung stochastischer Prozesse - die Annahme statisch normalverteilter Deckungsbeiträge für die zukünftige Periode  $t^*$  wie folgt darstellen:

$$(1) \quad \begin{aligned} DB_{t^*}^j &= E(DB_{t^*}^j) + \chi_{t^*}^j \\ &= \frac{1}{N} \cdot \sum_{t=1980}^{1980+N} DB_t^j + \chi_{t^*}^j, \text{ mit } N = t^* - 1980 \end{aligned}$$

Wir nutzen bereits hier diese Schreibweise, da wir in der Folge zunehmend komplexere stochastische Prozesse betrachten. Der zukünftige Deckungsbeitrag  $DB_{t^*}^j$  ergibt sich also ganz allgemein aus seinem Erwartungswert  $E(DB_{t^*}^j)$  und einer  $N[0, \sigma_{t^*}^j]$ -normalverteilten Zufallskomponente  $\chi_{t^*}^j$ . Der Erwartungswert entspricht bei der statischen Verteilungsannahme dem Mittelwert, und die Standardabweichung des Störterms  $\sigma_{t^*}^j$  entspricht der Standardabweichung der bis zum Planungszeitpunkt beobachteten Einzeldeckungsbeiträge.

### 2.1.2 Prognosemodell 2: Lineare Zeitreihenmodelle

Mit Blick auf eine realitätsgetreue Modellierung der zukünftigen Wertentwicklung von Zufallsvariablen kommt stochastischen Prozessen eine maßgebliche Bedeutung zu. Der Begriff „stochastischer Prozess“ impliziert, dass man auf der Basis einer Zeitreihenanalyse das Entwicklungsmuster von Zufallsvariablen analysiert und Annahmen über die Wahrscheinlichkeitsverteilungen von Zufallsvariablen zu zukünftigen Zeitpunkten trifft. AutoRegressive-Integrierte-Moving-Average-Modelle der Ordnung  $p, d$  und  $q$  (ARIMA( $p, d, q$ )-Modelle) sind lineare Zeitreihenmodelle. Aufgrund ihrer Flexibilität lässt sich durch die Prozessklasse der ARIMA( $p, d, q$ )-Modelle eine Vielzahl stochastischer ökonomischer Prozesse abbilden (vgl. z.B. LANGBEHN und MOHR, 1978).

Das zur jeweiligen Einzeldeckungsbeitragszeitreihe am besten „passende“ ARIMA( $p, d, q$ )-Modell lässt sich unter Anwendung der Box-Jenkins-Testprozedur bestimmen (BOX und JENKINS, 1976). Ganz allgemein lässt sich ein AR( $p$ )-Prozess wie folgt darstellen:

$$(2) \quad \begin{aligned} DB_{t^*}^j &= E(DB_{t^*}^j) + \chi_{t^*}^j \\ &= \alpha_0^j + \sum_{u=1}^p \alpha_u^j \cdot DB_{t^*-u}^j + \chi_{t^*}^j \end{aligned}$$

mit:  $\sum_{u=1}^p |\alpha_u^j| < 1$

$\alpha_0^j$  kennzeichnet eine Konstante und  $\alpha_u^j$  die zu schätzenden Gewichtungsfaktoren für die letzten  $p$  Beobachtungswerte  $DB_{t^*-u}^j$ . Im vorliegenden Fall liefert die Box-Jenkins-Testprozedur für alle Einzeldeckungsbeiträge und alle Analysejahre einen AR(1)-Prozess ( $p = 1$ ); d.h., die Verteilung des zukünftigen Wertes des jeweiligen Einzeldeckungsbeitrages kann aus dem letzten Beobachtungswert abgeleitet werden und (2) vereinfacht sich zu:

$$(3) \quad DB_{t^*}^j = \alpha_0^j + \alpha_1^j \cdot DB_{t^*-1}^j + \chi_{t^*}^j$$

Wie bei Prognosemodell 1 ergibt sich der zukünftige Deckungsbeitrag aus dem Erwartungswert  $E(DB_{t^*}^j)$  und einer  $N[0, \sigma_{t^*}^j]$ -normalverteilten Zufallskomponente  $\chi_{t^*}^j$ . Dieser Erwartungswert sowie die Standardabweichung der zukünftigen Verteilung unterscheiden sich jedoch von denen des statischen Modells.

### 2.1.3 Prognosemodell 3: Ergebnisoffene Identifizierung stochastischer Prozesse

Neuere Forschungsergebnisse betonen die Bedeutung nicht-linearer statistischer Abhängigkeiten in Zeitreihen (z.B. CHAVAS and HOLT, 1991). Diese können aber von den Standard-Testverfahren (vgl. BOX and JENKINS, 1976), die a priori von Linearität ausgehen, nicht erkannt werden. Im Ergebnis wirklich ergebnisoffener statistischer Tests könnten sich auch nichtlineare stochastische Prozesse ergeben. Insbesondere im Bereich der Finanzanalysen finden deshalb zur Vorhersage von Aktienkursen, Zinssätzen etc. vermehrt künstliche neuronale Netze Anwendung (vgl. z.B. BISHOP, 1995; HAYKIN, 1999). Zwar können neuronale Netze neben linearen auch nichtlineare funktionale Zusammenhänge approximieren, gleichzeitig ist das Ergebnis neuronaler Netze aber immer ein implizites Modell, d.h. es wird kein Zeitreihenmodell in Form einer mathematischen Gleichung ausgewiesen. Außerdem ist die Entwicklung eines geeigneten Prognosemodells mittels neuronaler Netze ein zeitaufwändiger, experimenteller Prozess, der ein entsprechend hohes Maß an Vorwissen des Anwenders voraussetzt.

Als mögliche Alternative zu neuronalen Netzen bei der Identifizierung potenziell vorhandener nichtlinearer stochastischer Zusammenhänge bietet sich die auf IVACHNENKO (1983) zurückgehende Methode der heuristischen Selbstorganisation mathematischer Modelle an (vgl. auch FARLOW, 1984; MUELLER und LEMKE, 2003). Diese ermöglicht es, auf der Grundlage empirischer Daten ein Zeitreihenmodell „optimaler Komplexität“ mit a priori nicht bekannter Struktur automatisch zu erstellen. Sowohl die Parameter als auch die Struktur des optimalen Modells werden in einem iterativen Prozess vom „Rechnerprogramm“ ermittelt.

Eine spezielle Klasse der parametrischen Selbstorganisationsalgorithmen bilden die Algorithmen mit gruppenweiser Behandlung der Daten (GMDH - Group Method of Data Handling). GMDH-Algorithmen kombinieren den von künstlichen neuronalen Netzen bekannten konnektionistischen Ansatz mit dem klassischen Verfahren der Regression. GMDH-Algorithmen erstellen polynomiale Prozessmodelle der allgemeinen Form:

$$(4) \quad \begin{aligned} DB_{t^*}^j &= \gamma_0^j + \sum_{u=1}^p \gamma_u^j \cdot DB_{t^*-u}^j + \chi_{t^*}^j \\ &+ \sum_{u=1}^p \sum_{v=1}^p \gamma_{u,v}^j \cdot DB_{t^*-u}^j \cdot DB_{t^*-v}^j \\ &+ \sum_{u=1}^p \sum_{v=1}^p \sum_{w=1}^p \gamma_{u,v,w}^j \cdot DB_{t^*-u}^j \cdot DB_{t^*-v}^j \cdot DB_{t^*-w}^j + \dots \end{aligned}$$

Diese Polynome können bspw. den (die) vorhergehenden Beobachtungswert(e) in unterschiedlicher Gewichtung sowie deren Quadrat(e) oder auch unterschiedlichste multi-

plikative Verknüpfungen zwischen diesen Werten berücksichtigen. Damit ergibt sich auch schon bei einer begrenzten Anzahl berücksichtigter zurückliegender Beobachtungswerte eine exponentiell ansteigende Anzahl möglicher nichtlinearer Terme. Ein Blick auf (4) zeigt, dass dies letztlich einem AR( $p$ )-Prozess (obere Zeile) entspricht, der um nichtlineare Komponenten (untere Zeilen) erweitert ist.

Sowohl die optimale Dimension des Polynoms als auch die Parameter werden im Rahmen der selbstorganisierenden Modellgenerierung bestimmt, indem, ausgehend von einem sehr einfachen Modell, die Komplexität Schritt für Schritt erhöht wird. Um zu bestimmen, welches Modell eine optimale Komplexität aufweist, wird der Datensatz vom Programm automatisch in einen Trainings- und einen Testdatensatz aufgeteilt (cross-validation). Anhand des Trainingsdatensatzes werden eine Vielzahl von Modellhypothese erzeugt und anschließend anhand des Testdatensatzes evaluiert. Das Modell optimaler Komplexität ist gefunden, sobald eine Überanpassung (Overfitting) der Trainingsdaten festzustellen ist. Dies ist dann der Fall, wenn bei einer weiteren Erhöhung der Komplexität des Prognosemodells zufällige Zusammenhänge in den Daten (White-Noise) abgebildet werden und damit die Vorhersagegenauigkeit des Modells für den Testdatensatz sinkt.

In der hier vorliegenden Anwendung wird für jeden Einzeldeckungsbeitrag mit Hilfe des Softwaretools KNOWLEDGEMINER (Version 5.0.9 für Windows) ein ggf. nichtlineares Regressionsmodell mittels GMDH automatisch aus den Daten erzeugt und explizit in Form einer Regressionsgleichung ausgegeben.<sup>1</sup>

## 2.2 Empirische Erhebung der Restriktionen

### 2.2.1 Betriebliche Kapazitäts- und Fruchtfolgerestriktionen

Es werden Daten von vier Marktfruchtbetrieben in Brandenburg erhoben. Die Betriebe 1, 2 und 3 befinden sich etwa 50 km westlich und Betrieb 4 ca. 100 km nordöstlich von Berlin. Von den Betrieben 1 bis 3 werden Informationen bzgl. ihrer Hauptkulturen Winter- und Sommerweizen, Winterroggen, Winter- und Sommergerste, Winterraps, Körnermais, Non-Food-Raps und Stilllegung erhoben. Die Hauptkulturen in Betrieb 4 beschränken sich aufgrund der schlechteren Standortbedingungen und persönlichen Präferenzen des Betriebsleiters auf Winterweizen, Winterroggen, Wintergerste, Winterraps, Non-Food-Raps und Stilllegung. Flächen, auf denen im jeweiligen Jahr Sonderkulturen, wie z.B. Luzerne, Öllein oder Erbsen, angebaut wurden, werden beim Leistungsvergleich zwischen normativ bestimmten und empirisch beobachteten Produktionsprogrammen in allen vier Betrieben ausgeklammert. Ihr Anteil ist insbesondere in den Betrieben 1 bis 3 gering. Außerdem sind für die jährlich wechselnden Sonderkulturen keine statistisch

gesicherten Verteilungsinformationen zu gewinnen. Die Beschränkung auf die Hauptbetriebsfläche ist jedoch nicht weiter problematisch, weil sie lediglich zu einer Niveauverschiebung sowohl des empirischen als auch des optimierten Gesamtdeckungsbeitrages führt und somit für den Leistungsvergleich irrelevant ist. Zuckerrüben werden ebenfalls nicht berücksichtigt. Ihre Rentabilität ist im Vergleich zu anderen Kulturen so hoch, dass sie ohnehin in maximal möglichem Produktionsumfang angebaut werden sollten.

Die Betriebsleiter werden bezogen auf die letzten sechs Jahre hinsichtlich der jährlichen Einzeldeckungsbeiträge, der Faktorausstattung (Arbeitskräfte und Hauptbetriebsfläche) und der Fruchtfolgerestriktionen (minimal bzw. maximal möglichen Anteilen einzelner Produktionsverfahren) befragt. Informationen bezüglich der möglichen Anbauumfänge werden ergänzend aus den ebenfalls erfragten empirischen Produktionsprogrammen der zurückliegenden Jahre abgeleitet (vgl. Tabelle 2). Beispielsweise hat der Leiter von Betrieb 1 angegeben, maximal 50 % seiner Hauptbetriebsfläche mit Weizen bewirtschaften zu wollen. Ein Blick in die zurückliegenden Produktionsprogramme zeigt jedoch, dass in der Vergangenheit bis zu 53,5 % der Fläche mit Weizen bestellt wurden.

Die im Durchschnitt der letzten sechs Jahre mit den oben genannten Hauptkulturen bewirtschaftete Fläche beträgt 729 ha in Betrieb 1, 1 111 ha in Betrieb 2, 1 210 ha in Betrieb 3 und 175 ha in Betrieb 4. Dazu werden in Betrieb 1 drei, in Betrieb 2 fünf, in Betrieb 3 vier und in Betrieb 4 eine Arbeitskraft (AK) eingesetzt. Zudem wird sowohl die Anzahl der erwarteten Feldarbeitstage als auch die maximal verfügbare und von den einzelnen Verfahren beanspruchte Arbeitszeit in den Zeitabschnitten März/April, Mai/Juni, Mitte Juli/Mitte September und Mitte September/Mitte November von den Landwirten erfragt.

### 2.2.2 Die zusätzliche betriebliche Varianzrestriktion

Die Risikoeinstellung des Landwirts wird über die von ihm akzeptierte Gesamtdeckungsbeitragsvarianz des empirischen Programms berücksichtigt. Dazu werden zunächst die tatsächlichen Umfänge der einzelnen Verfahren sowie die Standardabweichungen und Korrelationskoeffizienten (der Störterme) der Einzeldeckungsbeiträge erfasst, die sich im Ergebnis der jeweiligen Zeitreihenanalyse ergeben. Die Störterme der Einzeldeckungsbeiträge bezeichnen die Differenzen zwischen den tatsächlich beobachteten Einzeldeckungsbeiträgen und den Erwartungswerten zu den einzelnen Zeitpunkten, die sich unter Verwendung des jeweiligen Prognosemodells ergeben. In der Tendenz gelten ähnliche Korrelationskoeffizienten zwischen den Einzeldeckungsbeiträgen der pflanzlichen Produktionsverfahren wie in MUBHOFF und HIRSCHAUER (2004: 274) berechnet.

Da annahmegetreu allein die  $J$  additiv verknüpften Einzeldeckungsbeiträge mit Unsicherheit behaftet sind und ihren Störtermen eine Normalverteilung zugrunde liegt, kann die *Gesamtdeckungsbeitragsvarianz des empirischen Produktionsprogramms*  $V_{emp}$  analog zur Varianz eines Portfolios, das sich aus  $J$  Vermögenspositionen zusammensetzt, berechnet werden (vgl. JORION, 1997: 150):

$$(5) \quad V_{emp} = \sum_{j=1}^J (x_{i^*emp}^j \cdot \sigma^j)^2 + 2 \cdot \sum_{j=1}^J \sum_{k < j} x_{i^*emp}^j \cdot \sigma^j \cdot x_{i^*emp}^k \cdot \sigma^k \cdot \rho^{j,k}$$

<sup>1</sup> Während bei der Schätzung von ARIMA( $p,d,q$ )-Modellen die Normalverteilung für die Störterme eine implizite Annahme darstellt, können die Störterme der Modelle, die mittels GMDH-Algorithmen geschätzt werden, jede beliebige Verteilung aufweisen. Im Ergebnis von Chi-Quadrat-, Kolmogorov-Smirnov- und Anderson-Darling-Test zeigt sich aber, dass für die Störterme der hier betrachteten Einzeldeckungsbeitragszeitreihen die Normalverteilung auf einem Signifikanzniveau von 5 % nicht abgelehnt werden kann.

**Tabelle 1. Betriebsspezifische Restriktionen bzgl. der zu realisierenden Umfänge einzelner Kulturen (Angaben in % der Hauptbetriebsfläche)**

	Betrieb 1 (Ø 729 ha; Ø 3 AK; Ø 44 Bodenpunkte)		Betrieb 2 (Ø 1 111 ha; Ø 5 AK; Ø 38 Bodenpunkte)		Betrieb 3 (Ø 1 210 ha; Ø 4 AK; Ø 45 Bodenpunkte)		Betrieb 4 (Ø 175 ha; Ø 1 AK; Ø 30 Bodenpunkte)	
	Minimum	Maximum	Minimum	Maximum	Minimum	Maximum	Minimum	Maximum
Weizen	0,0	53,5	15,0	35,0	20,0	54,0	0,0	47,8
Roggen	0,0	40,8	0,0	40,0	0,0	45,0	13,4	70,0
Gerste	0,0	40,0	5,0	30,0	10,0	30,0	0,0	30,0
Raps	0,0	22,1	0,0	20,3	0,0	22,7	5,0	15,0
Körnermais	0,0	30,0	0,0	50,0	0,0	40,0	0,0	0,0
Stilllegung*	–	–	20,0	33,3	–	–	2,2	33,3
Stilllegung oder Non-Food-Raps**	10,0	33,3	–	–	10,0	33,3	10,8	33,3

\* reine Stilllegung

\*\* offene Wahl zwischen reiner Stilllegung und Non-Food-Raps

Quelle: eigene Erhebung

Dabei kennzeichnen  $\rho^{j,k}$  die Korrelationskoeffizienten (der empirischen Störterme) der Einzeldeckungsbeiträge der Produktionsverfahren  $j$  und  $k$ .  $\sigma^j$  bzw.  $\sigma^k$  bezeichnen die Standardabweichung (der Störterme) der Einzeldeckungsbeiträge. Korrelationskoeffizient und Standardabweichung werden auf der Grundlage der empirischen Daten bis zum jeweiligen Planungszeitpunkt bestimmt.  $x_{t^*,emp}^j$

bzw.  $x_{t^*,emp}^k$  steht für das tatsächliche Gewicht (Anbauumfang) der einzelnen Produktionsverfahren im empirischen Produktionsprogramm.

Die *Gesamtdeckungsbeitragsvarianz des optimierten Produktionsprogramms*, die wir mit  $V$  bezeichnen, ist ganz analog zu (5) zu bestimmen. Es ist dabei nur zu berücksichtigen, dass anstelle der beobachteten Anbauumfänge  $x_{t^*,emp}^j$

bzw.  $x_{t^*,emp}^k$  nun die optimierten Anbauumfänge  $x_{t^*}^j$  bzw.  $x_{t^*}^k$  einzusetzen sind.

Zu beachten ist, dass die Varianz des Gesamtdeckungsbeitrages bei Annahme von statischen Verteilungen für die Einzeldeckungsbeiträgen nur dann mit Hilfe von (5) (analytisch) bestimmt werden kann, wenn man Normalverteilungen für alle Einzeldeckungsbeiträge unterstellt (vgl. DOPPLER und MÄRZ, 1989). Beim Rückgriff auf stochastische Prozesse ist die analytische Bestimmung der Varianz des Gesamtdeckungsbeitrages gemäß (5) möglich, wenn alle stochastischen Einzeldeckungsbeiträge normalverteilte Störterme oder wenn alle gleichermaßen transformierten (z.B. logarithmierten) Zufallsvariablen normalverteilte Störterme aufweisen. Das Erste ist hier der Fall. Bei komplexeren Sachverhalten, wie bspw. bei Prozessen mit nicht-normalverteilten Störtermen, muss auf eine numerische Bestimmung der Varianz des Gesamtdeckungsbeitrages z.B. mittels stochastischer Simulation zurückgegriffen werden (vgl. MUBHOFF und HIRSCHAUER, 2004). Dies gilt im Übrigen auch, wenn zusätzliche Risikoquellen wie Unsicherheit in den Nebenbedingungen (z.B. Anzahl der Feldarbeitstage) berücksichtigt werden soll.

### 2.3 Optimierung der Alternativprogramme und Durchführung des Leistungsvergleichs

Auf der Grundlage der durch die Zeitreihenanalyse zum Planungszeitpunkt  $t^* - 1$  verfügbaren Informationen wird für jeden Betrieb für das jeweilige Planzieljahr  $t^*$  im Sinne einer quasi ex-ante Planung ein optimiertes Alternativprogramm bestimmt, indem der Erwartungswert für den Gesamtdeckungsbeitrag  $E(GDB)$  unter Maßgabe der Ergebnisse des jeweiligen Prognosemodells für die Einzeldeckungsbeiträge maximiert wird. Das Optimierungsproblem kann mathematisch wie folgt definiert werden:

$$\text{maximiere}_{x_{t^*}^j} E(GDB) = \sum_{j=1}^J E(DB_{t^*}^j) \cdot x_{t^*}^j$$

unter den Nebenbedingungen

$$(6) \quad \sum_{j=1}^J a_{t^*}^{i,j} \cdot x_{t^*}^j \leq b_{t^*}^i, \text{ für } i = 1, 2, \dots, I$$

$$V \leq V_{emp}$$

$$x_{t^*}^j \geq 0, \text{ für } j = 1, 2, \dots, J$$

Der Zielfunktionskoeffizient  $E(DB_{t^*}^j)$  kennzeichnet den erwarteten Deckungsbeitrag je Einheit der Produktionsaktivität  $j$  für das Planzieljahr  $t^*$ , der sich beim Informationsstand zum Planungszeitpunkt  $t^* - 1$  (d.h. bei Kenntnis der Zeitreihe bis  $DB_{t^*-1}^j$ ) auf der Grundlage eines der drei betrachteten Prognosemodelle ergibt.  $x_{t^*}^j$  beschreibt die optimierten Umfänge der Produktionsverfahren.  $b_{t^*}^i$  bezeichnet die für das Planzieljahr zur Verfügung stehenden Kapazitäten der Faktoren  $i$ , und  $a_{t^*}^{i,j}$  bezeichnet die Faktoransprüche je Einheit der einzelnen Produktionsaktivität.  $V_{emp}$  bzw.  $V$  steht für die Gesamtdeckungsbeitragsvarianz des empirischen bzw. des optimierten Produktionsprogramms. Zu bestimmen sind die Produktionsumfänge  $x_{t^*}^j$ , die unter Be-

achtung der Restriktionen zum maximalen Zielfunktionswert führen. Es sei darauf hingewiesen, dass  $E(GDB)$  gezielt zur Bezeichnung des erwarteten Gesamtdeckungsbeitrages des optimierten Produktionsprogramms genutzt wird. Dies ermöglicht eine Unterscheidung zum erwarteten Gesamtdeckungsbeitrag  $E(GDB_{emp})$ , der im Entscheidungszeitpunkt  $t^* - 1$  aufgrund des vom Landwirt tatsächlich aufgestellten Produktionsprogramms zu erwarten war.

Wie aus (6) zu ersehen ist, werden bei der Optimierung folgende Punkte berücksichtigt:

- Es wird immer der Informationsstand zum jeweiligen Planungszeitpunkt zugrunde gelegt; d.h. dass beispielsweise für die Bestimmung des optimierten Produktionsprogramms im Jahr 1998 nur Deckungsbeiträge bis 1998 als bekannt vorausgesetzt werden. Die im Planzieljahr 1999 erzielten Deckungsbeiträge fließen *nicht* in die jeweilige Datenauswertung und Optimierung ein.
- Die subjektive Risikoeinstellung der Landwirte wird bei der Optimierung modellendogen berücksichtigt, indem die Gesamtdeckungsbeitragsvarianz des empirischen Programms als zusätzliche Restriktion aufgenommen wird. Dies ermöglicht eine subjektive Entscheidungsunterstützung unter Berücksichtigung der individuellen Risikoeinstellung.
- Die Entscheidungsunterstützung ist als partieller Planungsansatz darauf beschränkt, ausgehend von den als gegeben angenommenen pflanzenbaulichen Fähigkeiten des Betriebsleiters die vorteilhafteste Kombination der Produktionsverfahren anzuzeigen. Eine Handlungsempfehlung bzgl. der technischen Ausgestaltung einzelner Verfahren (Pflanzenschutz, Düngintensität etc.) erfolgt nicht.

Das Besondere der hier dargestellten Vorgehensweise der Optimierung unter Unsicherheit, das unabhängig von der Wahl des Prognosemodells gilt, lässt sich durch den Vergleich mit allgemeinen EV-Modellen zeigen: Bei der Optimierung mit EV-Modellen wird zunächst der Erwartungswert des Gesamtdeckungsbeitrages für verschiedene vorgegebene Varianzen des erwarteten Gesamtdeckungsbeitrages maximiert (vgl. Abbildung 2, linke Bildhälfte). Aus den sich ergebenden effizienten Kombinationen von Erwartungswert und Varianz *könnte* bei bekanntem Risikoaversionskoeffizienten bzw. bekannter Risikoprämie modellendogen das optimale Produktionsprogramm für den jeweiligen Landwirt bestimmt werden. Angesichts der schwierigen Schätzung des Risikoaversionskoeffizienten (vgl. HUDSON et al., 2005) müssen dem Landwirt die effizienten Kombinationen von Erwartungswert und Varianz vorgelegt werden. Er muss (modellexogen) das Produktionsprogramm auswählen, das er bei seiner Risikoneigung bevorzugt.

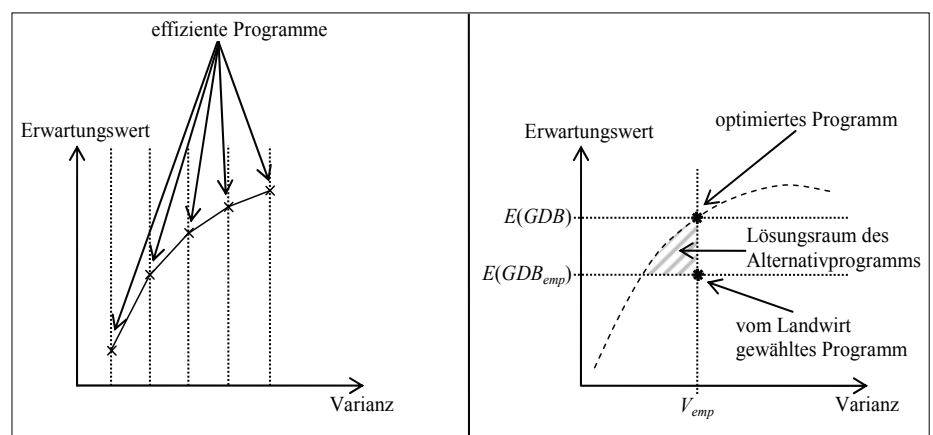
Im Sinne einer pragmatischen Herangehensweise und im Gegensatz zu allgemeinen EV-Modellen

wird bei der hier vorgeschlagenen Vorgehensweise der Erwartungswert des Gesamtdeckungsbeitrages für eine bereits empirisch beobachtete Bereitschaft, Risiko zu übernehmen, maximiert. Konkret wird die Gesamtdeckungsbeitragsvarianz des tatsächlichen Programms  $V_{emp}$ , die implizit die subjektive Risikoeinstellung der Landwirte ausdrückt, bei der Optimierung als Obergrenze berücksichtigt (vgl. Abbildung 2, rechte Bildhälfte). Mit anderen Worten: Beim Alternativprogramm sind im jeweiligen Planungszeitpunkt allenfalls höhere bzw. gleiche erwartete Gesamtdeckungsbeiträge bei gleicher oder geringerer Varianz möglich.

Die Positive Quadratische Programmierung (PQP; vgl. z.B. HOWITT, 1995) versucht das empirisch beobachtete Verhalten über mathematische Programmierungsmodelle nachzustellen. Unter Anwendung einfacher linearer Programmierungsverfahren sowie kapazitäts- und fruchtfolgebedingter Restriktionen lassen sich allerdings empirisch beobachtete Programme vielfach nicht abbilden. Dies wird im Rahmen der PQP - unter Annahme der Optimalität empirischer Entscheidungen - damit begründet, dass nicht alle Restriktionen in adäquater Weise berücksichtigt werden. Dies umfasst bei einer eindimensionalen Zielfunktion auch vernachlässigte Nebenziele, wie sie sich z.B. aus Risikoaversion bzw. nicht-monetären Zielsetzungen der Landwirte (Wunsch nach Reduzierung der Arbeitsbelastung etc.) ergeben können. Mittels Kalibrierung, d.h. der Einführung zusätzlicher „künstlicher“ Restriktionen, werden deshalb im Programmierungsmodell zunächst die im Ausgangsjahr beobachteten Aktivitätsumfänge „erzungen“. Die für diese Restriktionen entstehenden Dualwerte werden dann dazu verwendet, um die sog. PQP-Terme zu spezifizieren, die als nichtlineare Kostenterme in die Zielfunktion integriert werden. Die Spezifizierung einer derartigen Zielfunktion führt dazu, dass über das Programm die beobachteten Umfänge abgebildet werden können, ohne dass feste Grenzen vorgegeben werden müssen.

Ganz im Gegensatz zu der PQP besteht der Kern der hier vorgeschlagenen Vorgehensweise gerade darin, die Performance eines normativen Planungsmodells im Vergleich zum empirisch beobachtbaren Planungsverhalten zu untersuchen. Trotz der grundsätzlich unterschiedlichen Zielset-

**Abbildung 2. Klassische Vorgehensweise im EV-Modell (linke Bildhälfte) vs. endogenisierte Berücksichtigung der Risikoeinstellung (rechte Bildhälfte)**



Quelle: eigene Darstellung

zung weist die Vorgehensweise der Berücksichtigung der Varianz des empirisch beobachteten Programms eine strukturelle Ähnlichkeit mit dem Kalibrierungsschritt in der PQP auf. Anstelle von Variantenrechnungen, die aufzeigen, ob eine geringfügige Erhöhung der zulässigen Varianz möglicherweise eine deutliche Erhöhung des Gesamtdeckungsbeitrages und damit ein vom jeweiligen Landwirt ebenfalls akzeptiertes Programm liefert, könnte auch im Rahmen dieses normativen Ansatzes die Zielfunktion modifiziert werden.

Das mit (6) beschriebene quadratische Optimierungsproblem wird für jeden der betrachteten vier Betriebe, für jedes der Planzieljahre 1999 bis 2004 und unter Maßgabe der Ergebnisse jedes der drei Prognosemodelle separat gelöst. Dazu kommt jeweils das heuristische Suchverfahren der genetischen Algorithmen zur Anwendung (vgl. MUBHOFF und HIRSCHAUER, 2003), da das mathematische Programmierungsproblem für den in der üblichen Tabellenkalkulationssoftware MS-EXCEL verfügbaren „Solver“ zu groß ist.

Das optimierte Produktionsprogramm wird den Betriebsleitern vorgelegt, um es auf Umsetzbarkeit und Akzeptanz zu prüfen. Gegebenfalls erfolgen eine Berücksichtigung vorher vernachlässigter bzw. von den Landwirten nicht genannter Restriktionen und eine erneute Optimierung. Damit kommt es auf jeden Fall zu einem für den jeweiligen Betriebsleiter „akzeptablen Alternativprogramm“. Für den abschließenden Vergleich wird der Gesamtdeckungsbeitrag  $GDB$  berechnet, den man durch das optimierte Programm erzielt hätte:

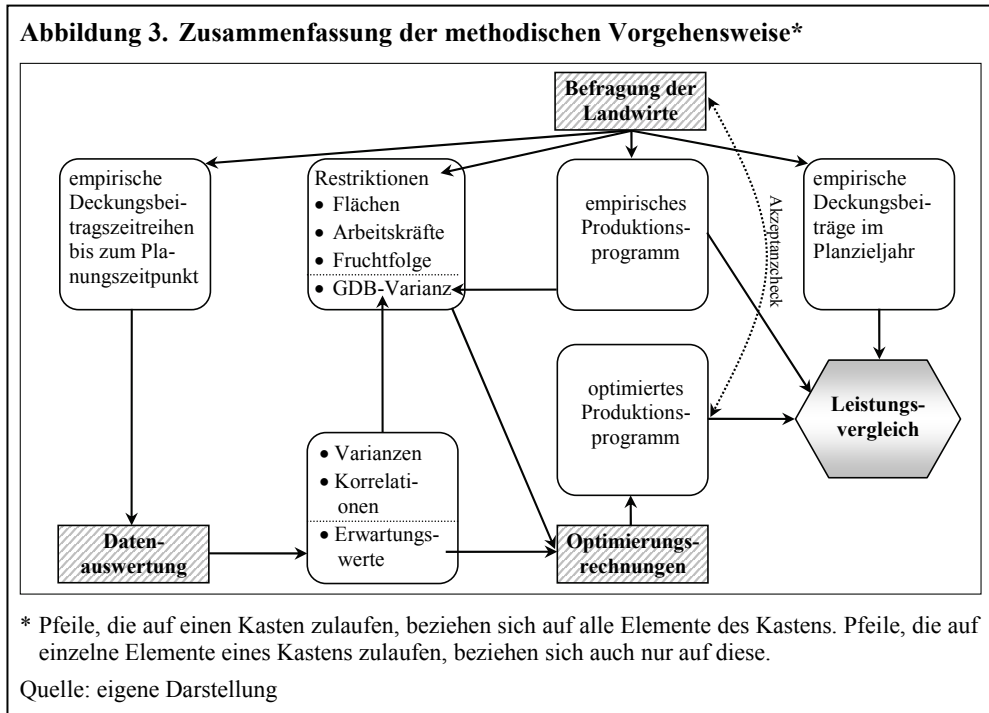
$$(7) \quad GDB = \sum_{j=1}^J DB_{t^*}^j \cdot x_{t^*}^j$$

Dabei kennzeichnet  $DB_{t^*}^j$  die tatsächlichen Einzeldeckungsbeiträge im Planzieljahr, und  $x_{t^*}^j$  bezeichnet die im Alternativprogramm geplanten Umfänge der Produktionsverfahren. Diesem hypothetisch erzielbaren Gesamtdeckungsbeitrag  $GDB$  wird der empirische Gesamtdeckungsbeitrag  $GDB_{emp}$  gegenübergestellt. Er ergibt sich ganz analog zu (7). Es ist nur zu berücksichtigen, dass an Stelle von  $x_{t^*}^j$  die von den Landwirten tatsächlich durchgeführten Anbauumfänge der einzelnen Produktionsverfahren  $x_{t^*,emp}^j$  einzusetzen sind.

Ausdrücklich zu betonen ist an dieser Stelle, dass  $GDB$  bzw.  $GDB_{emp}$  den Gesamtdeckungsbeitrag bezeichnet, der

mit dem optimierten Programm im Planzieljahr erzielt worden wäre bzw. der mit dem tatsächlichen Programm im Planzieljahr erzielt wurde.  $E(GDB)$  bzw.  $E(GDB_{emp})$  bezeichnet demgegenüber den *erwarteten* Gesamtdeckungsbeitrages des optimierten bzw. des vom Landwirt tatsächlich aufgestellten Produktionsprogramms basierend auf dem Informationsstand zum Planungszeitpunkt.

Zusammenfassend ist die methodische Vorgehensweise in Abbildung 3 grafisch veranschaulicht.



Die hier gewählte methodische Vorgehensweise beinhaltet die Module (1) Befragung der Landwirte, (2) Datenauswertung, (3) Optimierungsrechnungen und (4) den abschließenden Leistungsvergleich. Vom jeweiligen Landwirt erhoben werden Informationen hinsichtlich der empirischen Deckungsbeitragszeitreihen bis zum Planungszeitpunkt, der betriebspezifischen Restriktionen, dem tatsächlich vom Landwirt umgesetzten Produktionsmix und der empirischen Deckungsbeiträge im Planzieljahr. Die empirischen Deckungsbeitragszeitreihen bis zum jeweiligen Planungszeitpunkt fließen in die Datenauswertung ein, deren Ergebnis Prognosemodelle für die jeweiligen Einzeldeckungsbeiträge sind. Die Prognosemodelle liefern einen Erwartungswert für das Planzieljahr und Informationen über Varianzen sowie Korrelationen zwischen den beobachteten Einzeldeckungsbeiträgen. Unter Rückgriff auf die Anbauumfänge der einzelnen Kulturen im empirisch beobachteten Produktionsprogramm sowie die Varianzen und Korrelationen der Einzeldeckungsbeiträge kann die vom Landwirt implizit akzeptierte Gesamtdeckungsbeitragsvarianz bestimmt werden. Die betriebspezifischen Restriktionen inklusive der Varianzrestriktion und die Erwartungswerte für die Einzeldeckungsbeiträge fließen in die Optimierungsrechnungen ein. Das im Ergebnis der Optimierungsrechnungen bestimmte Produktionsprogramm wird den Landwirten zwecks Akzeptanzchecks vorgelegt. Die empirischen Einzeldeckungsbeiträge im Planzieljahr werden anschließend



herangezogen, um den abschließenden Leistungsvergleich zwischen dem empirischen und dem optimierten Produktionsprogramm vorzunehmen. Nochmals sei betont, dass die im Planzieljahr erzielten Einzeldeckungsbeiträge weder in die Datenauswertung noch in die Optimierungsrechnungen einfließen, sondern nur für den abschließenden Leistungsvergleich herangezogen werden.

### 3. Modellergebnisse

Bislang kommen in keinem der betrachteten Betriebe methodisch fundierte Optimierungsrechnungen zur Anwendung. Vielmehr erfolgt die Produktionsplanung in weitgehend nicht formalisierter Form. In Tabelle 2 sind die Mittelwerte der jährlichen Gesamtdeckungsbeiträge dargestellt, die von den einzelnen Landwirten mit ihrem tatsächlichen Produktionsprogramm über den betrachteten Zeitraum erzielt wurden. Weiterhin sind die Gesamtdeckungsbeiträge angezeigt, die sich bei den jeweiligen optimierten Alternativprogrammen unter Anwendung der unterschiedlichen Prognosemodelle ergeben hätten. Zu beachten ist, dass die ausgewiesene Steigerung/Verminderung des Gesamtdeckungsbeitrages zu einem Mehrgewinn/Mehrverlust in gleicher absoluter Höhe geführt hätte. Prozentual wäre die Gewinnänderung deutlich höher.

In der ersten Zeile von Tabelle 2 ist das hypothetische Verbesserungspotenzial dargestellt, das sich ergäbe, wenn ein „perfektes Prognosemodell“ vorhanden wäre, das die tatsächlich erzielten Deckungsbeiträge exakt vorhersagen könnte. Über alle Betriebe und Jahre hinweg ließe sich bei dergestalt vollkommener Information durchschnittlich ein um 15,92 % höherer Deckungsbeitrag erzielen. Dieses Verbesserungspotenzial hört sich zunächst recht beeindruckend an, ergibt sich aber eben nur bei einer perfekten Prognose der Einzeldeckungsbeiträge, die natürlich niemals möglich ist. In jeder Zeitreihe ist immer ein gewisses Maß an unsystematischen bzw. nicht-prognostizierbaren Zufallsfehlern (White-Noise) enthalten. Insofern kann das hier ausgewiesene Verbesserungspotenzial zunächst nur als Indiz dafür gewertet werden, dass die Rentabilität empirischer Programmentscheidungen durch Optimierungsverfahren kombiniert mit geeigneten Prognoseverfahren gesteigert werden könnte.

In den folgenden Zeilen von Tabelle 2 ist dargestellt, inwieweit die verschiedenen Prognosemodelle dieses Verbesserungspotenzial tatsächlich ausschöpfen. Die zweite Ergebniszeile von Tabelle 2 verdeutlicht, dass mit Prognosemodell 1 (Annahme statischer Verteilungen) im Durchschnitt der betrachteten sechs Jahre nur in Betrieb 2 ein Gesamtdeckungsbeitrag hätte erzielt werden können, der deutlich höher ist als der tatsächlich vom Landwirt realisierte. In Betrieb 4 wäre immerhin noch eine geringfügige Steigerung von knapp 2 % möglich gewesen. In Betrieb 1 und 3 hätte eine formale Optimierung auf der Grundlage des Prognosemodells 1 dagegen circa 5 % bzw. 3 % Einbußen gegenüber den von den Landwirten realisierten Programmen gebracht. Bei einer näheren Analyse der Ergebnisse für Betrieb 2 zeigt sich, dass die einzige Produktionsumstellung in einer Verminderung des Körnermaisanteils zugunsten von Stilllegung, Winterroggen und Winterweizen besteht. Körnermais ist vergleichsweise unrentabel und auch in den Programmentscheidungen der anderen drei

betrachteten Betriebe quasi bedeutungslos. Die Aufnahme eines 15%igen Körnermaisanteils in das empirische Produktionsprogramm des Betriebes 2 muss also als ein grober Planungsfehler angesehen werden, der auch durch Optimierungsverfahren basierend auf Prognosemodell 1 ausgemerzt werden kann. Über alle vier Betriebe ist die Änderung des Gesamtdeckungsbeitrages nahezu null. Das bedeutet, dass die „Standardvorgehensweise“ der Bestimmung des Produktionsprogramms keine geeignete Entscheidungsunterstützung für die Unternehmenspraxis liefert.

Wie aus der dritten und vierten Ergebniszeile von Tabelle 2 hervorgeht, hätte im Gegensatz zu den eher ernüchternden Ergebnissen in Zeile 2 im Durchschnitt der betrachteten sechs Jahre in allen vier Betrieben ein deutlich höherer Gesamtdeckungsbeitrag erzielt werden können, wenn die Planung des Anbauprogramms durch Optimierungsverfahren auf der Grundlage systematischer Zeitreihenanalysen unterstützt worden wäre. Im Durchschnitt der sechs Planzieljahre und über alle vier Betriebe hinweg hätten die optimierten Alternativprogramme, die auf Prognosemodell 3 (ergebnisoffene Identifizierung stochastischer Prozesse) beruhen, zu einem um 7,97 % höheren Gesamtdeckungsbeitrag geführt. Die auf der Grundlage linearer Zeitreihenmodelle optimierten Alternativprogramme hätten allerdings auch schon eine Verbesserung von 7,90 % geliefert.<sup>2</sup> Prognosemodell 3 schneidet im Vergleich zu Prognosemodell 2, bei gleichzeitig deutlich erhöhtem Planungsaufwand, also nur geringfügig besser ab. Dies zeigt, dass es auch bei der Planung zu abnehmenden Grenzerträgen kommt.

Die auf der Grundlage systematischer Zeitreihenanalysen bestimmten Alternativprogramme wären den empirischen Programmentscheidungen im Durchschnitt der Jahre in allen vier Betrieben überlegen gewesen: Betrieb 1 hat im Mittel der letzten sechs Jahre auf seiner Hauptbetriebsfläche tatsächlich einen Deckungsbeitrag von 323 002 € erzielt. Durch Optimierung auf der Grundlage von Prognosemodell 3 hätte im Durchschnitt der Jahre ein Deckungsbeitrag von 349 028 € erzielt werden können. Der Gesamtdeckungsbeitrag in Betrieb 1 wäre also in den letzten sechs Jahren um durchschnittlich 8,06 % bzw. 26 026 € pro Jahr höher ausgefallen. In Betrieb 2 wäre der durchschnittliche jährliche Gesamtdeckungsbeitrag um 14,97 % (48 749 €), in Betrieb 3 um 3,23 % (13 943 €) und in Betrieb 4 um 4,72 % (3 725 €) höher gewesen.

In Tabelle 3 sind die Gesamtdeckungsbeiträge der sechs Planzieljahre 1999 bis 2004 aufgezeigt, die von den einzelnen Landwirten mit den tatsächlichen Programmentscheidungen der Jahre 1998 bis 2003 erzielt wurden bzw. mit den Alternativprogrammen auf der Grundlage von Prognosemodell 3 hätten erzielt werden können. Die Ergebnisse lassen sich kurz wie folgt zusammenfassen:

<sup>2</sup> Ergänzend sei an dieser Stelle erwähnt, dass sich im Mittel aller Betriebe und Jahre eine Steigerung des Gesamtdeckungsbeitrages um 4,38 % ergeben würde, wenn abweichend von Prognosemodell 1 eine (lineare) Trendbereinigung der Einzeldeckungsbeitragszeitreihen vorgenommen werden würde (Signifikanzniveau: 5 %). Auch diese Planungsvariante ist den optimierten Anbauprogrammen auf der Basis von Prognosemodell 2 und 3 also deutlich unterlegen. Dies ist darin begründet, dass ein linearer Trend nur eine mögliche systematische Komponente in einer Zeitreihe darstellt.

**Tabelle 2. Mittelwert tatsächlicher vs. erzielbarer Gesamtdeckungsbeiträge über alle Jahre (Angaben in € bzw. %)**

	Betrieb 1		Betrieb 2		Betrieb 3		Betrieb 4		Summe über alle Betriebe	
	empirisch	optimiert	empirisch	optimiert	empirisch	optimiert	empirisch	optimiert	empirisch	optimiert
hypothetisches „perfektes Prognosemodell“	323 002	360 063	325 636	413 944	432 118	482 390	78 894	87 826	1 159 650	1 344 224
		11,47 %		27,12 %		11,63 %		11,32 %		15,92 %
Prognosemodell 1: Statische Verteilungsannahmen		307 874		360 656		420 384		80 286		1 169 200
		-4,68 %		10,75 %		-2,72 %		1,76 %		0,82 %
Prognosemodell 2: Lineare Zeitreihenmodelle	323 002	344 690	325 636	373 466	432 118	450 237	78 894	82 878	1 159 650	1 251 259
		6,71 %		14,69 %		4,19 %		5,05 %		7,90 %
Prognosemodell 3: Ergebnisoffene Prozessidentifizierung		349 028		374 385		446 061		82 619		1 252 093
		8,06 %		14,97 %		3,23 %		4,72 %		7,97 %

Quelle: eigene Berechnungen

**Tabelle 3. Tatsächliche vs. erzielbare Gesamtdeckungsbeiträge in den einzelnen Jahren auf der Grundlage von Prognosemodell 3 (Angaben in € bzw. %)**

Planzieljahr t*	Betrieb 1		Betrieb 2		Betrieb 3		Betrieb 4		Summe über alle Betriebe	
	empirisch	optimiert	empirisch	optimiert	empirisch	optimiert	empirisch	optimiert	empirisch	optimiert
1999	480 466	511 087	370 455	506 530	609 084	622 857	66 239	66 636	1 526 245	1 707 110
		6,37 %		36,73 %		2,26 %		0,60 %		11,85 %
2000	339 544	347 890	295 934	315 797	462 911	479 697	76 887	80 250	1 175 276	1 223 634
		2,46 %		6,71 %		3,63 %		4,37 %		4,11 %
2001	434 064	436 099	410 929	434 361	593 912	577 690	74 546	77 211	1 513 451	1 525 360
		0,47 %		5,70 %		-2,73 %		3,57 %		0,79 %
2002	240 468	243 935	303 739	320 128	308 538	321 348	59 748	65 338	912 493	950 749
		1,44 %		5,40 %		4,15 %		9,36 %		4,19 %
2003	168 913	274 723	255 150	326 454	263 096	285 644	59 389	63 460	746 548	950 282
		62,64 %		27,95 %		8,57 %		6,85 %		27,29 %
2004	274 556	280 436	317 608	343 042	355 169	389 127	136 556	142 820	1 083 889	1 155 425
		2,14 %		8,01 %		9,56 %		4,59 %		6,60 %
Mittelwert über alle Jahre	323 002	349 028	325 636	374 385	432 118	446 061	78 894	82 619	1 159 650	1 252 093
		8,06 %		14,97 %		3,23 %		4,72 %		7,97 %

Quelle: eigene Berechnungen

- Die formal optimierten Alternativprogramme wären den von den Landwirten tatsächlich getroffenen Programm-entscheidungen in 23 von 24 Fällen überlegen gewesen. Obwohl hier nicht dargestellt, sei darauf hingewiesen, dass die Rentabilität der Alternativprogramme, die auf der Grundlage der Ergebnisse von Prognosemodell 1 (Prognosemodell 2) erstellt wurden, die Rentabilität empirischer Programm-entscheidungen in 11 von 24 (23 von 24) Fällen übertrifft.
- Der Gesamtdeckungsbeitrag des tatsächlichen Produktionsprogramms des Betriebes 3 im Jahr 2001 ist - als einzige Ausnahme - höher als der des Alternativprogramms. Allerdings war auch hier der im Jahr 2000 zu erwartende Gesamtdeckungsbeitrag des Alternativprogramms um 1,5 % höher als der des tatsächlichen Programms. Dies zeigt, dass eine Fehlplanung zwar im Einzelfall zu einem besseren Ergebnis führen kann, nicht jedoch im Durchschnitt der Jahre.
- In den einzelnen Jahren hätte durch eine formale Optimierung auf der Grundlage von Prognosemodell 3 der erzielte Gesamtdeckungsbeitrag um bis zu 62,64 % gesteigert werden können (Betrieb 1 im Planzieljahr 2003).

In Tabelle 4 wird die tatsächliche durchschnittliche Produktionsstruktur der sechs Planzieljahre mit der formal optimierten in der Rentabilität überlegenen Produktionsstruktur verglichen, die sich auf der Grundlage von Prognosemodell 3 ergeben hätte. Dies erlaubt vorsichtige Schlussfolgerungen, worin systematische Programmfehler in den einzelnen Betrieben bestanden haben könnten. In der Tendenz übereinstimmende Ergebnisse ergeben sich beim Vergleich mit der Optimierung auf der Grundlage von Prognosemodell 2.

Das wohl auffälligste Ergebnis ist, dass in allen vier Betrieben tendenziell deutlich mehr Roggen hätte angebaut werden sollen. Winterroggen ist augenscheinlich das Produktionsverfahren, welches in Brandenburg aufgrund des ungünstigen Produktionsstandortes und unsicherer Witterung besonders wettbewerbsfähig ist. In Betrieb 1 und 3 hätte der Roggenanteil zu Lasten des Wintergerste- und des Wintertrapsanteils ausgeweitet werden sollen, in Betrieb 2 hauptsächlich zu Lasten des Wintergerste-, Wintertraps- und

Körnermaisanteils und in Betrieb 4 durch eine Reduzierung des Wintergersteanteils. Neben dem besonderen Planungsfehler in Betrieb 2 bauen also alle Landwirte im Vergleich zu den optimierten und überlegenen Alternativprogrammen im Schnitt deutlich zu wenig Winterroggen und zu viel Wintergerste an. In den Betrieben 1, 2 und 3 ist zudem der Wintertrapsanteil zu hoch.

Dies deutet auf systematische Entscheidungsfehler hin. Mit Blick auf die evolutorische Ökonomik (vgl. z.B. NELSON und WINTER, 1982) und die einfachen Heuristiken im tatsächlichen Entscheidungsverhalten von Menschen (vgl. z.B. GIGERENZER und SELTEN, 2001) könnte eine Erklärung hierfür darin liegen, dass Landwirte bei ihren Entscheidungen zwar auf ihr im Laufe von Jahrzehnten gewonnenes Erfahrungswissen zurückgreifen, gleichzeitig aber eine im Zeitablauf veränderte relative Wettbewerbsfähigkeit von Verfahren nicht schnell genug in ihre Entscheidungsheuristiken aufnehmen. Mit anderen Worten: Vielleicht lernen sie zu langsam (beschränkte Rationalität), handeln aus Routine und passen sich bei der Wahl ihres Produktionsprogramms veränderten Rahmenbedingungen nicht schnell genug an. Der in allen betrachteten Betrieben festgestellte zu geringe Winterroggenanteil bspw. ließe sich - leicht spekulativ, aber plausibel - dadurch erklären, dass die Landwirte die enormen Züchtungsforschnitte bei Roggen sowie zunehmend prekäre Niederschlagsmengen in Brandenburg noch nicht voll bei ihrer Entscheidung berücksichtigen. Gleichzeitig mag für die Betriebe 1, 2 und 3 der höhere Wintertrapsanteil in den 90er Jahren die optimale Strategie dargestellt haben, insbesondere weil eine vergleichsweise hohe Flächenprämie für Raps gezahlt wurde. Im Zuge der AGENDA-2000 wurden die Flächenprämien für Raps und Getreide allerdings vereinheitlicht.

Natürlich dürfen aus den in den hier betrachteten Betrieben gefundenen systematischen Programmfehlern nicht ohne weiteres Empfehlungen für zukünftige Anbauprogramme abgeleitet werden. Dies gilt insbesondere für eine pauschale Erhöhung des Roggenanteils, da bekanntermaßen die Roggenintervention im Jahr 2004 abgeschafft wurde. Demzufolge ist zu bedenken, ob dies einen politikbedingten Strukturbruch der entsprechenden Zeitreihe verursachen kann.

**Tabelle 4. Tatsächlicher vs. optimierter Anteil der einzelnen Fruchtarten im Mittel der betrachteten Jahre bei Prognosemodell 3 (Angaben in %)**

	Betrieb 1			Betrieb 2			Betrieb 3			Betrieb 4		
	empirisch	optimiert	Differenz	empirisch	optimiert	Differenz	empirisch	optimiert	Differenz	empirisch	optimiert	Differenz
Winterweizen	43,5	41,7	-1,8	22,1	25,9	3,8	42,4	40,8	-1,6	32,3	41,0	8,7
Sommerweizen	0,0	0,9	0,9	0,0	0,0	0,0	0,0	0,6	0,6	-	-	-
Winterroggen	22,3	39,0	16,6	16,2	38,3	22,1	19,3	30,7	11,4	24,4	31,7	7,3
Wintergerste	13,6	0,0	-13,6	8,2	2,7	-5,6	15,8	8,6	-7,2	17,5	0,0	-17,5
Sommergerste	1,2	0,0	-1,2	0,0	2,5	2,5	0,0	1,5	1,5	-	-	-
Wintertraps	9,5	6,4	-3,1	15,6	8,8	-6,8	10,4	6,9	-3,5	9,4	13,2	3,7
Körnermais	0,0	0,0	0,0	15,1	0,2	-14,9	1,7	0,0	-1,7	-	-	-
Non-Food-Raps	9,2	12,1	2,8	0,0	0,1	0,1	6,4	8,4	2,0	12,4	9,3	-3,1
Stilllegung	0,8	0,1	-0,7	22,8	21,5	-1,3	3,9	2,4	-1,5	3,9	4,7	0,8

Quelle: eigene Berechnungen

#### 4. Zusammenfassung und Ausblick

Bei der in diesem Beitrag behandelten Thematik scheint es sich zunächst um eine „alte“ Diskussion zu handeln. Das hier identifizierte Verbesserungspotenzial einer Planung, die sich auf formale Optimierungsverfahren und eine systematische Zeitreihenanalyse stützt, ist allerdings von ihrem Ausmaß her bemerkenswert: Im Durchschnitt der letzten sechs Jahre sind die mittels Optimierungsverfahren bestimmten Alternativprogramme den tatsächlichen Anbaustrategien aller vier betrachteten Betriebe *deutlich* überlegen. Es lohnt sich also, die Information, die in den empirischen Deckungsbeitragszeitreihen bis zum jeweiligen Planungszeitpunkt steckt, systematisch für die Planung zu nutzen. Dabei musste hier aufgrund des wendebedingten Strukturbruchs Anfang der 90er Jahre auf „gestückelte“ Einzeldeckungsbeitragszeitreihen zurückgegriffen werden. Durchaus vorstellbar ist also, dass eine verbesserte Datenlage (z.B. in der Zukunft) das Verbesserungspotenzial des vorgeschlagenen Planungsansatzes noch erhöhen würde. Zudem wird das Problem der Berücksichtigung der Risikoeinstellung in der Optimierung durch die dargelegte Vorgehensweise gelöst. Die Risikoeinstellung, die in der akzeptierten Gesamtdeckungsbeitragsvarianz des vom Landwirt selbst geplanten Produktionsprogramms steckt, wird einfach als Restriktion in die Optimierung einbezogen. Im Sinne einer praxistauglichen Entscheidungsunterstützung müsste der Landwirt also in einem systematischen Planungsverfahren zunächst immer sein geplantes Produktionsprogramm ohne Unterstützung durch das Optimierungsverfahren benennen. Dann könnte ihm ein Alternativvorschlag gemacht werden, der bei gleicher oder geringerer Varianz zu einem höheren (erwarteten) Gesamtdeckungsbeitrag führt.

Allerdings ist zu betonen, dass der Einsatz komplexer Optimierungsverfahren, die auf eine Berücksichtigung des Risikos und der subjektiven Risikoeinstellung der Landwirte abzielen, nicht per se zu einer Verbesserung der Planung führt. Das Verbesserungspotenzial solcher formaler Verfahren ist in außerordentlichem Maße davon abhängig, dass die vorhandenen stochastischen Informationen durch eine adäquate Auswertung der zur Verfügung stehenden Daten auch tatsächlich bereitgestellt und genutzt werden. Die Standardvorgehensweise, bei der Unsicherheit über a priori unterstellte Normalverteilungen für die Zufallsvariablen bzw. über gleichgewichtete Vergangenheitswerte berücksichtigt wird, greift zu kurz. Schon bei Vorliegen eines einfachen Trends wird durch solch „vereinfachte stochastische Informationen“ der Prognosewert aufgrund seiner Konstruktion als Mittelwert der vergangenen Beobachtungswerte grundsätzlich falsch geschätzt. Die Tatsache, dass formalisierte Optimierungsmodelle sogar zu einer Verschlechterung der Planung führen, wenn solchermaßen verfälschte stochastische Informationen genutzt werden, könnte auch ein Erklärungsansatz dafür sein, dass Optimierungsverfahren bislang kaum zur praktischen Entscheidungsunterstützung bei der Anbauplanung eingesetzt werden. Die hier vorgestellte Fallstudie zeigt, dass erst die Kombination von systematischen Zeitreihenanalysen mit einem Optimierungsmodell, das die dadurch erschlossene stochastische Information auch zur Gänze verarbeitet, eine Verbesserung gegenüber einer intuitiv-heuristischen und gering formalisierten Planung der Unternehmenspraxis bringt.

In Anbetracht der Tatsache, dass in der vorliegenden Analyse lediglich vier Betriebe mit ähnlichen Standortbedingungen über einen Zeitraum von nur sechs Jahren evaluiert wurden, können die Ergebnisse nur als erstes Indiz dafür gewertet werden, dass Landwirte ihren Gewinn durch den Einsatz von Zeitreihenanalysen und Optimierungsverfahren tatsächlich deutlich steigern können. Da die Ergebnisse bezogen auf diese Fallstudien aber sehr eindeutig sind, sollte in weiterführenden Untersuchungen mit breiterer empirischer Datengrundlage die Robustheit und Überlegenheit des vorgeschlagenen Planungsverfahrens geprüft werden. Dabei sollten mögliche Einflussfaktoren, wie z.B. Region, Management und Größe, gezielt variiert werden.

Mit Blick auf eine Weiterentwicklung des beschriebenen Planungsmodells scheinen folgende Erweiterungen sinnvoll:

- In diesem Beitrag wurden große arrondierte Marktfruchtbetriebe betrachtet, die auch tatsächlich unabhängig von den Schlaggrößen jeden beliebigen Anteil der Produktionsverfahren an der Hauptbetriebsfläche umsetzen können. Eine Modellerweiterung dahingehend, dass eine ackerschlagbezogene Programmplanung durchgeführt wird, wäre zwar programmier- und rechentechnisch sehr viel aufwändiger, aber grundsätzlich möglich.
- Gegenstand dieses Beitrags ist die Managementaufgabe „Optimierung des Produktionsprogramms“ unter Maßgabe der im Betrieb vorhandenen Managementfähigkeit bzgl. der technologischen Ausgestaltung der Produktionsverfahren. Natürlich ließe sich die hier vorgeschlagene methodische Vorgehensweise im Sinne eines umfassenden Controllingansatzes dahingehend erweitern, dass die Bestimmung der optimalen technischen Ausgestaltung der Produktionsverfahren integriert wird. Zu beachten ist jedoch, dass nach einer solchen Verbesserung der Planung auf der Ebene der Ausgestaltung der Produktionsverfahren vergangene betriebsindividuelle Deckungsbeitragszeitreihen keine Aussagekraft für zukünftige Deckungsbeitragsentwicklungen mehr besitzen würden. Vielmehr müsste man dann auf disaggregierte Größen (Erträge, Preise, variable Kosten etc.) zurückgreifen.
- Die vom jeweiligen Betriebsleiter akzeptierte Varianz des Gesamtdeckungsbeitrages, die implizit im tatsächlichen Produktionsprogramm enthalten ist, wurde hier als feste Restriktion vorgegeben. Es wäre aber denkbar, dass der Landwirt auch bereit wäre, ein wenig mehr Varianz zu akzeptieren, wenn dies zu einem sehr viel höheren erwarteten Gesamtdeckungsbeitrag führt. Diesem Aspekt wurde hier keine Rechnung getragen. Die Eindeutigkeit der Ergebnisse leidet darunter jedoch nicht. Es ist vielmehr möglich, dass bei einer entsprechenden Modellerweiterung eine noch deutlichere Out-Performance möglich wäre. Dies könnte man überprüfen, indem man über Variantenrechnungen untersucht, ob durch eine geringfügig höhere Varianz der Erwartungswert für den Gesamtdeckungsbeitrag tatsächlich deutlich gesteigert werden kann.

Wie bei allen anderen ökonomischen Entscheidungen ist auch bei der Planung bzw. den angesprochenen Modellerweiterungen sicher zu stellen, dass der erwartete Mehraufwand durch den erwarteten Nutzen gerechtfertigt werden kann. Voraussichtlich ist hierfür eine kritische Betriebsgröße erforderlich, die die Ausnutzung von Skaleneffekten bei der Planung erlaubt.

## Literatur

- BISHOP, C.M. (1995): *Neural Networks for Pattern Recognition*. Clarendon Press, Oxford.
- BOKELMANN, W., N. HIRSCHAUER, U.J. NAGEL und M. ODENING (1996): *Landwirtschaftliche Beratung in Brandenburg. Eine Evaluierung erster Erfahrungen*. Margraf, Weikersheim.
- BOX, G.E.P. and G.M. JENKINS (1976): *Time Series Analysis: Forecasting and Control*. Holden-Day, San Francisco.
- BRANDES, W. (1974): *Wie analysiere und plane ich meinen Betrieb?* Parey, Hamburg.
- CHAVAS, J.P. and M.T. HOLT (1991): *On Non-linear Dynamics: The Case of the Pork Cycle*. In: *American Journal of Agricultural Economics* 73 (3): 819-828.
- DENT, J.B., S.R. HARRISON and K.B. WOODFORD (1986): *Farm Planning with Linear Programming: Concept and Practice*. Butterworths, Sydney.
- DOPPLER, W. und U. MÄRZ (1989): *Die Behandlung von Verteilungen in stochastischen Methoden der Betriebsplanung*. Schriften der Gesellschaft für Wirtschafts- und Sozialwissenschaften des Landbaues e.V. Münster-Hiltrup. Band 25: 353-362.
- FARLOW, S.J. (1984): *Self-Organizing Methods in Modeling. GMDH Type Algorithm*. Marcel Dekker, New York.
- GIGERENZER, G. and R. SELTEN (2001): *Bounded Rationality: The adaptive Toolbox*. MIT Press, Cambridge.
- HANF, C.H. (1991): *Lineare Programmierung und landwirtschaftliche Beratung (Oder: Wird wertvolle Ausbildungszeit an der Universität vergeudet?)*. In: *Betriebswirtschaftliche Mitteilungen der Landwirtschaftskammer Schleswig-Holstein* 432: 3-12.
- HARDAKER, J.B., R.B.M. HUIRNE, J.R. ANDERSON and G. LIEN (2004): *Coping with Risk in Agriculture*. 2<sup>nd</sup> Edition. CAB International, Wallingford.
- HAYKIN, S. (1999): *Neural Network: A Comprehensive Foundation*. Macmillan Publishing, New York.
- HAZELL, P.B.R. (1971): *A Linear Alternative to Quadratic and Semivariance Programming for Farm Planning Under Uncertainty*. In: *American Journal of Agricultural Economics* 53 (1): 53-62.
- HAZELL, P.B.R. and R.D. NORTON (1986): *Mathematical Programming for Economic Analysis in Agriculture*. Macmillan Publishing, New York.
- HOWITT R. (1995): *Positive Mathematical Programming*. In: *American Journal of Agricultural Economics* 77 (2): 329-342.
- HUDSON, D., K. COBLE and J. LUSK (2005): *Consistency of Risk Premium Measures*. In: *Agricultural Economics* 33 (1): 41-49.
- IVACHNENKO, A.G. (1983): *Inductive Method of Self-Organization of Complex System Models*. Naukova Dumka, Kiev (in Russian).
- JORION, P. (1997): *Value at Risk - The New Benchmark for Controlling Market Risk*. McGraw-Hill, New York.
- LANGBEHN, W. und W. MOHR (1978): *Prognosevergleich zwischen Box-Jenkins- und Schwingungsmodellen*. In: *Agrarwirtschaft* 27 (10): 297-307.
- LDS BRANDENBURG (Landesbetrieb für Datenverarbeitung und Statistik)(2003). *Auskunft per Fax*.
- MUELLER, J.A. and F. LEMKE (2003): *Self-Organizing Data Mining. Extracting Knowledge from Data*. Trafford Publishing, British Columbia.
- MUBHOFF, O. und N. HIRSCHAUER (2003): *Bewertung komplexer Optionen - Umsetzung numerischer Verfahren mittels MS-EXCEL und Anwendungsmöglichkeiten der Optionspreistheorie auf Sachinvestitionen -*. PD-Verlag, Heidenau.
- (2004): *Optimierung unter Unsicherheit mit Hilfe stochastischer Simulation und Genetischer Algorithmen*. In: *Agrarwirtschaft* 53 (7): 264-279.
- NELSON, R.R. and S.G. WINTER (1982): *An Evolutionary Theory of Economic Change*. Harvard University Press, Cambridge.
- ROBISON, L.J. and P.J. BARRY (1987): *The Competitive Firm's Response to Risk*. Macmillan, New York.
- ZMP-BILANZ (Zentrale Preis- und Marktberichtsstelle) (Getreide, Ölsaaten und Futtermittel). Bonn, verschiedene Jahrgänge.

## Danksagung

Für hilfreiche Kommentare, Anregungen und Kritik danken wir Prof. Dr. Martin Odening, zwei anonymen Gutachtern und den Herausgebern der „Agrarwirtschaft“. Oliver Mußhoff dankt der Klaus-Tschira-Stiftung, gemeinnützige GmbH, für die finanzielle Unterstützung.

Kontaktautor:

**DR. OLIVER MUBHOFF**

Humboldt-Universität zu Berlin,

Institut für Wirtschafts- und Sozialwissenschaften des Landbaus,

Fachgebiet Allgemeine Betriebslehre des Landbaus

Luisenstraße 56, 10099 Berlin

Tel.: 030-20 93 63 15, Fax: 030-20 93 64 65

E-Mail: oliver.musshoff@agr.ar.hu-berlin.de