

Institut für Pflanzenbau
Der Rheinischen Friedrich-Wilhelms-Universität Bonn
Lehrstuhl für Allgemeinen Pflanzenbau
Prof. Dr. W. Kühbauch

**Einsatz von Fernerkundungsdaten und bodengestützten Daten
zur regionalen Ertragsvorhersage von Braugerste (*Hordeum vulgare L.*)**

Inaugural-Dissertation
zur
Erlangung des Grades
Doktor der Agrarwissenschaften
(Dr. agr.)
der
Hohen Landwirtschaftlichen Fakultät
der
Rheinischen Friedrich-Wilhelms-Universität
zu Bonn

vorgelegt am 28.11.2003
von
Dipl.-Ing. Christof J. Weissteiner
aus St. Lorenzen (Südtirol/Italien)

Referent: Prof. Dr. W. Kühbauch

Co-Referent: Prof. Dr. G. Menz

Tag der mündlichen Prüfung: 30.04.2004

Kurzfassung

Einsatz von Fernerkundungsdaten und bodengestützten Daten zur regionalen Ertragsvorhersage von Braugerste (*Hordeum vulgare L.*)

Ernteprognosen erlauben die frühzeitige Ableitung von Informationen zur Versorgungslage des Braugerstenmarktes, wodurch die Braugerstenindustrie in der Lage ist, ihre Einkaufspolitik zu optimieren. Braugerste wird u. a. aufgrund ihrer Ansprüche vorwiegend in typischen Anbaubereichen kultiviert, dadurch können über regionale Beobachtungen Informationen über Anbauumfang und Wachstum gewonnen werden. In dieser Arbeit wurden Untersuchungen zur Anbaufläche und zum Flächenertrag von Braugerste (*Hordeum vulgare L.*), die in Deutschland vorwiegend als Sommergerste angebaut wird, in zwei Regionen in Südwestdeutschland durchgeführt. Es wurden zwei verschiedene Versionen von Ertragsprognosemodellen entwickelt, die auf einem empirisch-statistischen Ansatz beruhen. Als Eingabedaten sind einerseits multitemporale Fernerkundungsdaten, andererseits bodengestützte Daten wie meteorologische, phänologische, pedologische, agrarstatistische und administrative Daten verwendet worden.

Da das Ernteaufkommen sowohl von der Flächenausdehnung als auch vom Flächenertrag abhängig ist, wurde im ersten Schritt Sommergerste mittels überwachter multitemporaler Klassifikation bestimmt. Zum Einsatz kamen hierfür optische Fernerkundungsdaten (LANDSAT TM/ETM+), topographische Daten (Digitales Höhenmodell) und wissensbasierte Regeln für die Klassifikation. Letztere waren im Hinblick auf die spezielle phänologische Entwicklung der Kultur von Interesse und konnten zur Unterscheidung von ähnlichen Kulturen genutzt werden. Die Klassifikation erfolgte auf Basis einer pixelbasierten und objektorientierten Methode. In Flurstücken mit mehr als 2 ha konnten bis zu 73 % der Sommergersteflächen klassifiziert werden.

Die einfache Version des Ertragsprognosemodells basiert auf linearen Korrelationen zwischen Fernerkundungsdaten (NOAA-AVHRR-NDVI-Maximalwertkompositen) und agrarstatistischen Daten. In der Prozessierung der Fernerkundungsdaten wurden zudem Landbedeckungsdaten (CORINE *land cover*) genutzt. In einer erweiterten Version des Ertragsprognosemodells wurden zusätzlich meteorologische Daten (Temperatur, Evapotranspiration) und pedologische Daten integriert. Die Prognoseergebnisse wurden maßgeblich von der eingesetzten NDVI-Integrationszeitspanne beeinflusst. Der mittlere Prognosefehler (Abweichung von berichtetem zu prognostiziertem Ertrag) lag bei einer NDVI-Integration über die Kornfüllungsdauer hinweg bei 7,0 % für das einfache und bei 6,4 % für das erweiterte Ertragsprognosemodell.

Abstract - English

Use of Remote Sensing and Soilborne Data for Regional Yield Predictions of Malting Barley (*Hordeum vulgare L.*)

Yield forecasts are of high interest to the malting and brewing industry in order to allow the most convenient organisation of the respective purchasing policy of raw materials. Since malting barley, due to its special requirements, is predominantly cultivated in a limited set of growing regions, yield predictions can be limited to these regions of interest. Within this investigation, malting barley yield forecasts (*Hordeum vulgare L.*), in Germany mostly grown as spring barley, are performed for typical growing regions in South-Western Germany. Multitemporal remote sensing data on one hand and ancillary data such as meteorological, phenological, pedological, agrostistical and administrative data on the other hand are used as input data for two versions of prediction models, which were based on an empirical-statistical modelling approach.

Since spring barley production is depending on acreage and on the yield per area, classification is needed, which was performed by a supervised multitemporal classification algorithm, utilizing optical Remote Sensing data (LANDSAT TM/ETM+). The classification algorithm is considering spectral data, topographical data (Digital Elevation Model) and expert knowledge input. The latter is important with regard to the particular phenological development of the observed crop, an expertise which was used to distinguish it from similar crops. A pixel-based and an object-oriented classification algorithm were used for classification. For field plots larger than 2 ha up to 73 % of the spring barley area were classified.

The basic version of the yield estimation model was conducted by means of linear correlation of remote sensing data (NOAA-AVHRR NDVI Maximum Value Composites), CORINE land cover data and agrostistical data. In an extended version meteorological data (temperature, evapotranspiration) and soil data were incorporated. Yield predictions were significantly affected by the selected time span for NDVI integration. For NDVI time-integration across the corn-filling period, the mean deviation of reported and simulated yield was 7.0 % and 6.4 % for the basic and extended yield estimation model, respectively.

Inhaltsverzeichnis

1	Einleitung und Zielsetzung	1
2	Stand der Forschung	3
2.1	Braugerste	3
2.1.1	Pflanzenbauliche Grundlagen	3
2.1.2	Qualitätsanforderungen	4
2.1.3	Umwelteinflüsse.....	5
2.2	Landnutzungsklassifikation	6
2.3	Prognosemodelle	9
2.3.1	Prognosemodelle - Literaturübersicht	9
2.3.2	Problematiken der Prognosemodelle	16
2.3.3	Voraussetzungen eines Prognosemodells	19
2.3.4	Analyse potentiell geeigneter Prognosemodelle	21
3	Untersuchungsregion	25
3.1	Auswahl der Untersuchungsregionen	25
3.2	Naturräumliche Beschreibung der Untersuchungsregionen.....	27
3.2.1	Untersuchungsregion Rheinland-Pfalz (RLP).....	27
3.2.2	Untersuchungsregion Baden-Württemberg (BW).....	27
4	Datenerhebung und Datenverarbeitung	29
4.1	Fernerkundungsdaten	29
4.1.1	Hochauflösende Fernerkundungsdaten (LANDSAT TM/ETM+).....	29
4.1.2	Grobauflösende FE-Daten (NOAA-AVHRR NDVI MVC).....	33
4.2	Bodengestützte Daten	36
4.2.1	Meteorologische Daten	36
4.2.2	Phänologische und naturräumliche Daten.....	36
4.2.3	CORINE land cover	36
4.2.4	Pedologische Daten	37
4.2.5	Topographische Daten und Flurstücksdaten	37
4.2.6	Felddaten und Kartierung.....	37
4.2.7	Feldspektrometermessungen	38
4.2.8	Agrarstatistische Daten	38
4.2.9	Administrative Daten	38

4.3	Klassifikation	39
4.3.1	Klassifikationsmethoden	39
4.3.1.1	Pixelorientierte Klassifikation	40
4.3.1.2	Objektorientierte Klassifikation	41
4.4	Ertragsprognosemodell	46
4.4.1	Phänologie.....	49
4.4.2	NDVI-Akkumulation	52
4.4.3	Einfaches Prognosemodell – Funktionsweise.....	56
4.4.4	Erweitertes Prognosemodell – Funktionsweise	58
4.4.4.1	Bodendaten	60
4.4.4.2	Trockenstress in Abhängigkeit der Bodenbedeckung und Bodenart.....	60
4.4.4.3	Quantifizierung der Auswirkungen von Trockenstress	63
4.4.4.4	Quantifizierung der Auswirkungen von Temperaturstress.....	64
4.4.4.5	Angewandte Korrekturen für Temperatur- und Trockenstress.....	65
5	Ergebnisse und Diskussion.....	68
5.1	Klassifikationsergebnisse.....	68
5.2	Ergebnisse der Ertragsprognosen.....	72
5.2.1	Einfaches Ertragsprognosemodell.....	72
5.2.2	Erweitertes Ertragsprognosemodell	77
5.2.3	Sensitivitätsanalyse	81
6	Stellungnahme	85
7	Zusammenfassung	95
8	Literaturverzeichnis	99
9	Anhang	109

Abbildungsverzeichnis

Abbildung 1: Gliederung und Ablaufschema der vorliegenden Arbeit.....	2
Abbildung 2: Schwerpunkte des Braugersteinbaus in Mittel- und Westeuropa.	3
Abbildung 3: Übersichtskarte. Die Untersuchungsregionen liegen in Rheinland-Pfalz (RLP) und Baden-Württemberg (BW).....	26
Abbildung 4: Untersuchungsgebiet RLP mit Landkreisgrenzen, Lage der phänologischen Stationen, der Klimastationen sowie der kartierten Standorte. Die Karte ist hinterlegt mit dem Ausschnitt einer panchromatischen LANDSAT ETM-Aufnahme vom 30.7.01.	26
Abbildung 5: Untersuchungsgebiet BW mit Landkreisgrenzen, Lage der phänologischen Stationen, der Klimastationen sowie der kartierten Standorte. Die Karte ist hinterlegt mit dem Ausschnitt einer Pseudo-Echtfarbendarstellung (3-2-1) einer LANDSAT TM Aufnahme vom 1.4.01. Der südl. Teil des Landkreises Tuttingen wird nicht abgedeckt.	26
Abbildung 6: Reflektanzen eines konkreten Schlages (Epfendorf) von Sommergerste der LANDSAT-TM-Kanäle 1 - 4. LANDSAT-TM-Aufnahme vom 06.07.01 jeweils atmosphärenkorrigiert mit Modell COST bzw. ATCOR sowie nicht atmosphärenkorrigiert im Vergleich zum Feldspektrometer (<i>Fieldspec VNIR</i>). Die durchgeführte Atmosphärenkorrektur mit dem ATCOR-Modell zeigt die geringsten Abweichungen zu den Messungen des Feldspektrometers.....	31
Abbildung 7: Variationskoeffizient der Rückstreuung pseudoinvarianter Objekte (Industriedächer) für eine Zeitreihe von 5 Satellitenaufnahmen aus dem Jahr 2001 (Untersuchungsregion Rheinland-Pfalz), dargestellt für 4 LANDSAT-TM-Kanäle – mit und ohne Atmosphärenkorrektur (ATCOR).	33
Abbildung 8: Zeitreihe von 2-wöchigen NOAA-AVHRR-NDVI-Maximalwertkompositen 2002	35
Abbildung 9: Input-Daten der Klassifikation	39
Abbildung 10: Beispiel einer Zugehörigkeitsfunktion mit „scharfer“ Begrenzung. Das Objekt wird nur dann als Sommergerste klassifiziert, wenn der NDVI zwischen 0,15 und 0,3 liegt.....	43
Abbildung 11: Beispiel einer Zugehörigkeitsfunktion für die Klasse „Zuckerrübe“. Das Objekt wird bei einem NDVI < 0,6 nicht, bei einem NDVI > 0,65 als Zuckerrübe klassifiziert. Der Unschärfbereich liegt zwischen NDVI 0,6 und 0,65 (0,6..0,65) und verläuft über eine sigmoide Kurve. In diesem Bereich kann das Objekt als Zuckerrübe klassifiziert werden, wenn die Zugehörigkeitswahrscheinlichkeit zur Zuckerrübe höher ist als zu Konkurrenzklassen.....	43
Abbildung 12 a - b: Anteile der Getreidekulturen am Ackerland in den Untersuchungsregionen, der Bodennutzungshaupterhebung 1999 der Statistischen Landesämter RLP (a) und BW (b) entnommen.	47
Abbildung 13: Schematische Darstellung des einfachen und erweiterten Ernteprognosemodells. Durchgehende Linien bezeichnen Datenflüsse für das einfache Modell. Die unterbrochenen Linien bezeichnen die ergänzenden Datenflüsse des erweiterten Modells (grau hinterlegt).	49
Abbildung 14: Temperatursummen (<i>Growing Degree Days – GDD</i>) in Abhängigkeit des Julianisches Tages für die Eintrittsdaten 5 phänologischer Stadien. Das jeweils größere Symbol stellte den räumlichen Median (<i>Center of minimum distance – R. Median</i>) für das entsprechende phänologische Stadium dar. Abgebildet sind Daten aus ausgewählten phänologischen und meteorologischen Stationen in der Untersuchungsregion BW der Jahre 1987-1990. Das Bestimmtheitsmaß über alle phänologischen Phasen für die lineare Funktion liegt bei $R^2 = 0,93$	51
Abbildung 15: Entwicklung des NDVI in Abhängigkeit der Kalendertage (Julianischer Kalender) für die Untersuchungsregion BW (Polynom 2. Grades, $R^2 = 0,96$). Die Daten stammen aus LANDSAT-Daten des Jahres 2001. Um die Anpassungskurve annähernd durch das NDVI-Maximum zu zwingen, wurde dieses 100-fach höher gewichtet.....	53
Abbildung 16: Entwicklung des NDVI in Abhängigkeit der Temperatursumme (<i>Growing Degree Days</i>) für die Untersuchungsregionen BW und RLP. Die Daten stammen aus LANDSAT-Daten des Jahres 2001.	

Durch ein Polynom 3. Grades ($R^2 = 0,87$) ließ sich eine bessere Anpassung erzielen als durch eine Quadratfunktion ($R^2 = 0,67$). Um die Anpassungskurve annähernd durch das NDVI-Maximum zu zwingen, wurde dieses 100-fach höher gewichtet.	53
Abbildung 17: NDVI-Jahresverlauf, errechnet aus gemittelten „synthetischen täglichen“ AVHRR-NDVI- Daten aus beiden Untersuchungsregionen sowie berücksichtigte Zeiträume, über welche NDVI- Summen gebildet wurden. Mit Kal bezeichnete Zeitspannen sind über Kalendertage akkumuliert, mit GDD bezeichnete Zeitspannen mittels GDD. Zu beachten ist, dass es sich für GDD1 bis GDD4 um ungefähr dargestellte Zeitangaben handelt, da diese Zeitspannen auf Temperatursummen beruhen, welche nicht in allen Landkreisen denselben Kalendertagen entsprechen.	55
Abbildung 18: Datenflüsse des einfachen Ertragsprognosemodells mit NOAA-AVHRR.	57
Abbildung 19: Schematische Darstellung des erweiterten Ertragsprognosemodells. Das Modell besteht aus 3 Kompartimenten, den NOAA-Regressionen (analog dem einfachen Ertragsprognosemodell) sowie 2 weiteren Kompartimenten zur Modellierung von Trocken- bzw. Temperaturstress, deren Ergebnisse in die Korrekturen des über NOAA-AVHRR modellierten Ertrages einfließen.	59
Abbildung 20: Jahresverlauf der tatsächlichen Evapotranspiration (ET_a) auf 4 Modellböden. Als Grundlage dienten Messungen der Klimastation <i>Badenweiler</i> aus den Jahren 1951 - 1980 mit der Bodenbedeckung Gras.	61
Abbildung 21: Verhältnis von relativer Ertragsminderung ($1 - Y_a/Y_m$) und relativem Evapotranspirationsdefizit bzw. CWSI ($1 - ET_a/ET_p$) für Sommerweizen.	63
Abbildung 22: Optimierung der Stresskorrekturen anhand der <i>Simplex</i> -Methode: Ausgehend von den quantitativen Korrekturfaktoren wird – unter Berücksichtigung der Interaktionen zwischen den Korrekturfaktoren – die Dimensionierung der einzelnen Faktoren bestimmt. In die Korrektur fließen die jeweiligen quantitativen Werte für die Korrektur und der Dimensionierungsfaktors ein.	67
Abbildung 23: Beispiel einer pixelbasierten Sommergerste-Klassifikation am Standort Epfendorf in der Untersuchungsregion BW. Tatsächliche sowie klassifizierte Sommergerste ist graphisch überlagert dargestellt.	71
Abbildung 24: Objektorientierte Klassifikation im Vergleich zur pixelbasierten Klassifikation in Abbildung 23.	71
Abbildung 25: Verkleinerte Darstellung der Abbildung 23 (pixelbasierte Klassifikation). Deutlich zu sehen ist der <i>salt-and-pepper</i> -Effekt im Umfeld des untersuchten Standortes.	71
Abbildung 26: Objektorientierte Klassifikation im Vergleich zur pixelbasierten Klassifikation in Abbildung 25. Der <i>salt-and-pepper</i> -Effekt konnte deutlich reduziert werden.	71
Abbildung 27: Abweichungen der Prognosen von den offiziell berichteten Sommergersterträgen für die untersuchten NDVI-Akkumulationsperioden des einfachen und erweiterten Ertragsprognosemodells. Dargestellt sind die Abweichungen, die Mittelwerte und das 90-%-il aller Prognosen der Jahre 1995 – 2002 aller Landkreise beider Untersuchungsregionen als absolute %-Beträge (vergl. auch Anhang, Tabelle A 15)	74
Abbildung 28: Restdifferenz zwischen modelliertem Ertrag (erweitertes Ertragsprognosemodell) und berichtetem Ertrag (Quellen: Stat. Landesämter) für 4 Landkreise über einen Zeitraum von 8 Jahren. .	79
Abbildung 29 a – e: Sensitivität auf die Änderung des Ertrages für die Korrekturfaktoren 1 - 5 bei unterschiedlicher Dimensionierung. Die Ergebnisse sind beispielhaft für den Landkreis Freudenstadt (FDS) abgebildet.	82
Abbildung 30: Jährliche, aus 5 Korrekturen (Stressfaktoren) summierte Auf- und Abwertungen der aus NOAA-AVHRR-NDVI-MVC prognostizierten Sommergersterträge für 4 Landkreise.	83

Tabellenverzeichnis

Tabelle 1: Standorte der Untersuchungsregionen in RLP und BW	25
Tabelle 2: Satellitenaufnahmen der Untersuchungsgebiete in Rheinland-Pfalz (RLP) und Baden-Württemberg (BW).....	29
Tabelle 3: Minimale und maximale Abweichungen der Reflektanzen von gemessenen Reflektanzen mit Feldspektrometer am Beispiel des Schlages in Epfendorf.....	31
Tabelle 4: Flächenausmaß der untersuchten Regionen	38
Tabelle 5: Wissensbasierte Regeln und Schwellenwerte der pixelbasierten Klassifikation.....	41
Tabelle 6: Wissensbasierte Regeln und Schwellenwerte der objektorientierten Klassifikation, Untersuchungsregion RLP und BW. Schwellenwertbereiche mit unscharfer Grenze sind mit Punkten gekennzeichnet (z. B. 0,2...0,3), jene mit scharfer Grenze mit Bindestrich (z. B. 0,04 - 0,20).	45
Tabelle 7: Phänologische Phasen und ihr Eintritt nach Kalendertag (Julianischer Tag - JD) bzw. nach ermittelten Temperatursummen (Growing Degree Day – GDD, Basistemperatur 3 ° C) für die Untersuchungsregionen in Rheinland-Pfalz (RLP) und Baden-Württemberg (BW).....	52
Tabelle 8: Beschreibung der eingesetzten Korrekturfaktoren für Stress	65
Tabelle 9: Optimierte Parameter (Dimensionierungsfaktor) für für 4 Landkreise.	66
Tabelle 10: Ergebnisse der pixelorientierten Klassifikation in beiden Untersuchungsgebieten. Die Ergebnisse sind als Anzahl klassifizierter Schläge sowie als klassifizierte Fläche wiedergegeben. Die Schläge galten als klassifiziert, wenn mindestens 50 % oder 60 % der Fläche richtig klassifiziert wurden.....	69
Tabelle 11: Ergebnisse der objektorientierten Klassifikation in beiden Untersuchungsgebieten. Die Ergebnisse sind als Anzahl klassifizierter Schläge sowie als klassifizierte Fläche wiedergegeben. Die Schläge galten als klassifiziert, wenn mindestens 50 % oder 60 % der Fläche richtig klassifiziert wurden.	69
Tabelle 12: Modell- und Prognoseevaluation der NOAA-NDVI-Korrelationen mit Sommergerstenerträgen der Landkreise des Untersuchungsgebietes der Jahre 1995 - 2002 über Kalenderperioden (über Julianische Tage definiert).....	75
Tabelle 13: Modell- und Prognoseevaluation der NOAA-NDVI-Korrelationen mit Sommergerstenerträgen der Landkreise des Untersuchungsgebietes der Jahre 1995 - 2002 in Abhängigkeit der Phänologie (über GDD bestimmt).	76
Tabelle 14: Modell- und Prognoseevaluation der Jahre 1995 – 2002 des um Stressfaktoren erweiterten Sommergerste-Ertragsprognosemodells für die NDVI-Akkumulationsperiode GDD2 (ÄS - GR).....	78

Abkürzungsverzeichnis

AEZ	Agro-Ecological-Zone
AL	Auflaufen
ALK	Automatisierte Liegenschaftskarte
APAR	Absorbed Photosynthetic Active Radiation
ÄS	Ährenschieben
AS	Aussaat
ATKIS	Amtlich Topographisch-Kartographisches Informationssystem
AVHRR	Advanced Very High Resolution Radiometer
bit	Binary Integer
BRDF	Bidirectional Reflectance Distribution Function
BÜK	Bodenübersichtskarte
BW	Baden-Württemberg
CAMPOS	Cereal Accumulation Model Progressively Optimized by Satellite
CEREAL-YES	Cereal Yield Estimation System
CORINE	Coordinated Information on the European Environment
CWSI	Crop Water Stress Index
DFD	Deutsches Fernerkundungsdatenzentrum
DGK	Deutsche Grundkarte
DHM	Digitales Höhenmodell
DLR	Deutsches Zentrum für Luft- und Raumfahrt
DOY	Day of Year (= JD)
dt	Dezitonne
DWD	Deutscher Wetterdienst
DXF	Data Exchange Format
EC	Pflanzenentwicklungsstadium nach EUCARPIA (Europ. Ges. F. Pflanzenzüchtung)
EDBS	Einheitliche Datenbankschnittstelle
ESRI	Environmental Systems Research Institute
et al.	et alli
ET _a	aktuelle bzw. tatsächliche Evapotranspiration
ETM+	Enhanced Thematic Mapper
ET _p	potentielle Evapotranspiration
EU	Europäische Union
FAO	Food and Agriculture Organization of the United Nations
fAPAR	fraction of Absorbed Photosynthetic Active Radiation
FDS	Landkreis Freudenstadt
FE	Fernerkundung
FK	Feldkapazität
FS	Feldspektrometer
GARI	Green atmospherically resistant vegetation index
GCP	Ground Control Point
GDD	Growing Degree Day
GDD<x>	Akkumulationsperiode <x> nach Growing Degree Days
GR	Gelbreife
GERM	Landkreis Germersheim
GIS	Geographisches Informationssystem
GPS	Global Positioning System
ha	Hektar
JD	Julian Day
Kal<x>	Akkumulationsperiode <x> nach Kalendereinheiten

L	Lehm
LAC	Local Area Coverage
LACIE	Large Area Crop Inventory Experiment
LAI	Leaf Area Index
Lkreis	Landkreis
LLY	Lower Left Y Coordinate
IS	lehmiger Sand
MARS	Monitoring Agriculture with Remote Sensing
Max. Abw.	Maximale Abweichung
MERIS	Medium Resolution Imaging Spectrometer Instrument
MEZ	mitteleuropäische Zeit
Mio.	Million
Mittl. Abw.	Mittlere Abweichung
MODIS	Moderate Resolution Imaging Spectroradiometer
MPA	erwartete maximale photosynthetische Aktivität
MSS	Multispectral Scanner
MVC	Maximum Value Composite
N	Stickstoff
N.N.	Normalnull
NASA	National Aeronautics and Space Administration
NDVI	Normalized Difference Vegetation Index
nFK	nutzbare Feldkapazität
NOAA	National Oceanic and Atmospheric Administration
NUTS	Nomenclature des Unités Territoriales Statistiques
PAR	Photosynthetic Active Radiation
PVI	Perpendicular Vegetation Index
R	Korrelationskoeffizient
R.Median	Räumlicher Median (Center of minimum distance)
R ²	Bestimmtheitsmaß
RLP	Rheinland-Pfalz
RMS	Root Mean Square
ROTT	Landkreis Rottweil
RVI	Ratio Vegetation Index
S	Sand
SAVI	Soil Adjusted Vegetation Index
SCH	Schossen
sL	sandiger Lehm
SPOT	Satellite pour l'observation de la terre
SQL	Structured Query Language
Std.	Standardfehler
SÜW	Landkreis Südliche Weinstraße
t	Tonne
T _{Basis}	Basistemperatur
TIFF	Tagged Image File Format
TK	Topographische Karte
TM	Thematic Mapper
T _{max}	tägliche Maximaltemperatur
T _{min}	tägliche Minimaltemperatur
TSAVI	Transformed Soil Adjusted Vegetation Index
TUTT	Landkreis Tuttlingen
ULX	Upper Left X Coordinate
UTC	Universal Mean Time
VG	Verwaltungsgrenzen
VI	Vegetation Index
Y	Yield (Ertrag)
ZAK	Zollern-Alb-Kreis

1 Einleitung und Zielsetzung

In Deutschland werden jährlich etwa 2,4 Mio. t Braugerste benötigt. Im Jahr 2002 konnten etwa 1,5 Mio. t aus eigenem Bedarf gedeckt werden, der Rest musste – vorwiegend aus EU-Ländern – importiert werden. Das jährliche Aufkommen an Braugerste – in Deutschland wird dafür vorwiegend Sommergerste verwendet – unterliegt starken jährlichen Schwankungen (HOLM, 2003a; LINKER, 2002; LINKER, 2003). Daran gekoppelt ist im Regelfall auch die Qualität des Rohstoffes, welche hauptsächlich durch den Proteingehalt und den Vollgersteanteil definiert wird.

Aufgrund der starken Schwankungen des Braugersteaufkommens und frühzeitig abgeschlossener, verbindlicher Vorverträge zwischen Erzeugern und Abnehmern (Kontraktierung häufig 1 Jahr vor dem Liefertermin), können am Braugerstenmarkt Engpasssituationen auftreten, die zu erheblichen Preisschwankungen führen (HOLM, 2003b). Die Malzindustrie ist daher an Prognosen über das Ernteaufkommen und die Braugerstenqualität interessiert, um die Entwicklung der Marktpreise abzuschätzen und die Einkaufsstrategie und Logistik zu optimieren (JAGGARD & CLARK, 1990). Fehlinformationen, die auch bewusst gestreut werden können, führten in der Vergangenheit bisweilen zu extremen Preisentwicklungen. Händler und Einkäufer sind daher an einer objektiven Berichterstattung über die zu erwartenden Ernteerträge interessiert (GRAMLICH, 2003).

Braugerste wird aufgrund ihrer geringen Ansprüche an die Wasserversorgung und die Bodenbonität in regional begrenzten Gebieten angebaut. Diese Regionen können sich hinsichtlich der Phänologie, Klimatologie und Topographie deutlich unterscheiden. Das Ziel dieser Arbeit war deshalb die Entwicklung eines regionalspezifischen Prognosemodells, mit dem Erträge von Sommergerste deutlich vor der Ernte abgeschätzt werden können. Dies wird anhand von zwei typischen Anbauregionen in Südwestdeutschland demonstriert, unter der Voraussetzung, dass eine Anpassung an die regionalspezifischen Besonderheiten möglich ist. Ertragsprognosemodelle verschiedener Art werden seit langem zur Ertragsvorhersage eingesetzt, ein bekanntes Beispiel war das 1974 begonnene Projekt LACIE (*Large Area Crop Inventory Experiment* - ERICKSON, 1984; MAC DONALD & HALL, 1980). Dabei wurde das Getreideaufkommen mit aufwändigen Methoden und mit Hilfe der Fernerkundung in den weltweit wichtigsten Erzeugerländern prognostiziert. Unter der Bedingung der operationellen Umsetzbarkeit richtet sich das Augenmerk in der vorliegenden Arbeit dagegen auf ein relativ simples, einfach implementierbares und realisierbares System. Die Anzahl und Komplexität der Eingangsparameter in das Prognosemodell sind daher bewusst gering gehalten. Obwohl mit einem komplexeren Modell möglicherweise höhere Genauigkeiten erzielbar wären, kann damit im Regelfall nicht dasselbe Kosten-Nutzen-Verhältnis erreicht werden, was letztendlich für die Attraktivität des Systems ausschlaggebend ist. Der Schwerpunkt der Eingangsparameter liegt bei den Fernerkundungsdaten (NOAA-AVHRR), wodurch eine objektive Beobachtung des Vegetationsverlaufs gewährleistet ist. Zusätzlich kommen bodengestützte bzw. sogenannte konventionelle Daten zum Einsatz. Dazu gehören meteorologische, phänologische, pedologische, agrarstatistische und administrative Daten. Das Prognosemodell greift damit sowohl auf

Wirkungsgrößen des Pflanzenwachstums (z. B. Fernerkundungsdaten) als auch auf Ursachefaktoren (z. B. meteorologische Daten) zurück.

Neben der Prognose des erwarteten Flächenertrages wurden zur Identifikation der Sommergersteflächen Klassifikationsalgorithmen entwickelt, die auf multispektralen und multitemporalen Fernerkundungsaufnahmen beruhen (LANDSAT). Erst eine Kombination von Flächenertrag und Flächenausmaß erlaubt die Abschätzung der regionalen Produktion von Sommergerste. Es sollte aufgezeigt werden, ob und mit welchen Genauigkeiten die Klassifikation von Sommergerste in den Untersuchungsregionen mit verschiedenen Methoden möglich ist. Dabei kam sowohl ein pixelorientierter als auch ein objektorientierter Klassifikationsansatz zur Anwendung.

Die Gliederung und der Ablauf der hier erstellten Arbeit ist folgend graphisch dargestellt.

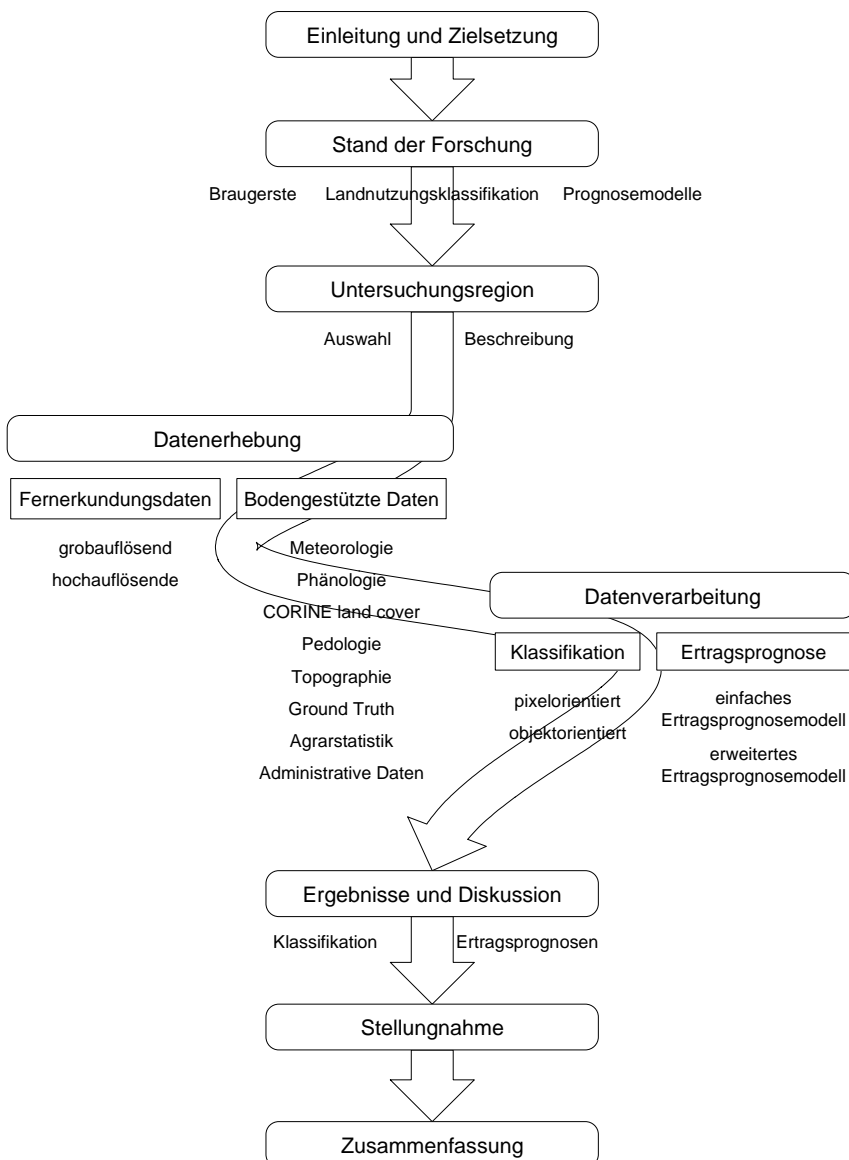


Abbildung 1: Gliederung und Ablaufschema der vorliegenden Arbeit

2 Stand der Forschung

2.1 Braugerste

2.1.1 Pflanzenbauliche Grundlagen

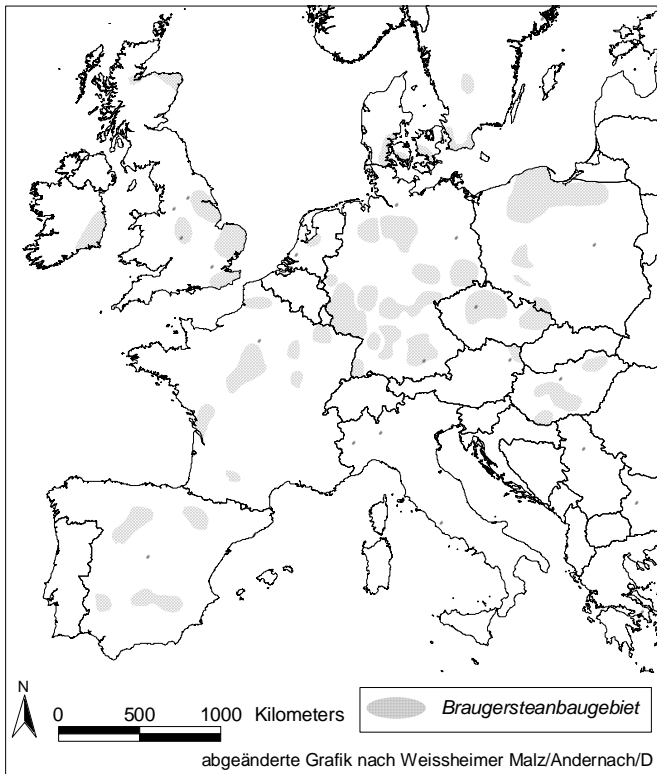


Abbildung 2: Schwerpunkte des Braugersteanbaus in Mittel- und Westeuropa.

Abbildung 2). Kennzeichnend für Braugerstestandorte sind häufig die Wasserknappheit, geringe Bodenbonität und raues Klima. Die allgemeine Entwicklung und die ertragsphysiologischen Besonderheiten der Sommergerste sind in der Literatur beschrieben (GEISLER, 1983; OEHMICHEN, 1986). Die Entwicklung der Pflanze vollzieht sich in 4 - 5 Monaten, die Aussaat findet in Deutschland regional unterschiedlich zwischen dem 10. März und Mitte/Ende April statt, die Ernte erfolgt ab Mitte Juli bis Ende August.

Das Wachstum verläuft in einer vegetativen und generativen Phase, beide lassen sich in mehrere phänologische Abschnitte unterteilen (z. B. Auflaufen, Bestocken, Schossen, Ährenschieben, Gelbreife), eine genauere Einteilung kann anhand von EC-Stadien vorgenommen werden (ZADOCK et al., 1974). Die Effekte von Kulturmaßnahmen bzw. Umweltbedingungen wirken sich je nach phänologischer Entwicklung unterschiedlich stark aus. Die für den Kornertrag besonders entscheidenden Stadien sind das Auflaufen und die generative Entwicklung. Die generative Phase

In Deutschland wird für Brauzwecke vorwiegend Sommergerste (*Hordeum vulgare L.*) verwendet. Von den in der Bundessortenliste (BSA, 2003) aufgeführten Sorten werden nur wenige in größerem Umfang angebaut. Im Untersuchungszeitraum dominierte in den Untersuchungsgebieten die Sorte *Scarlett*, eine zweizeilige Sommergerste. Die Sorte *Scarlett* zeichnet sich durch einen hohen Vollgersteanteil aus und verfügt über gute Malz- und Braueigenschaften, gleichzeitig wird sie aber auch charakterisiert durch unterdurchschnittliche Kornerträge, Schwächen in der Standfestigkeit, der Mehltau- und Zwergrostresistenz sowie im Rohproteingehalt. Der Anbau von Braugerste erfolgt vorwiegend in speziellen „Braugersteregionen“ (siehe

umfasst den Zeitraum um die Blüte sowie die Kornfüllungsphase und Abreife. Hinsichtlich der Ertragsbildung finden diese Stadien in der Literatur vermehrt Beachtung (z. B. DOORENBOS & KASSAM, 1979; LOOMIS & CONNOR, 1992). Wenn auch schwer zu quantifizieren, muss dennoch der Vorblütezeitraum für die Ertrags- und Qualitätsabschätzung berücksichtigt werden. Bereits im Vorblütezeitraum liegen größere Mengen an Kohlenstoff- und Stickstoff-Verbindungen in den vegetativen Pflanzenteilen des Getreides vor, die ins Korn transloziert werden können (GEBBING et al., 1995; SPIERZ, 1974).

Der Landwirt kann durch pflanzenbauliche Maßnahmen gezielt Einfluss auf die Pflanzenentwicklung und die Ertragskomponenten nehmen. Diese können vor allem durch Düngung, Pflanzenschutz, Saatkichte, Saatzeitpunkt, Sortenwahl, Vorfrucht, Bodenbearbeitung und Bewässerung gesteuert werden (DIEPENBROCK et al., 1999).

Hinsichtlich der Düngung kommt dem Stickstoff die größte Bedeutung zu. Er wird in allen Pflanzen zur Ausbildung des Photosyntheseapparates und der Ertragsorgane benötigt. In Braugerste erhöht er jedoch bei zu hoher Dosierung den Eiweißgehalt des Kornes und vermindert damit die Eignung zur Mälzung. Als Vorfrucht wird deshalb in der Regel keine Kultur angebaut, die in größeren Mengen Stickstoff im Boden hinterlässt, wie z. B. Leguminosenfutterpflanzen oder Raps. Sorteneinflüsse auf Ertrag und Qualität werden in der Literatur berichtet (BULMAN & SMITH, 1994; EAGLES et al., 1995), diese stehen jedoch in enger Wechselbeziehung zu Umwelteinflüssen und Anbaumaßnahmen und können daher kaum isoliert betrachtet werden (SCHELLING, 2000). Hinsichtlich des Saatzeitpunktes wird ein früherer Aussattermin für die Ertrags- und Qualitätsbildung allgemein günstiger eingestuft als ein späterer (DE RUITER & BROOKING, 1996).

2.1.2 Qualitätsanforderungen

Braugerste kann anhand innerer und äußerer Qualitätsmerkmale, die durch mechanische oder physikalisch-chemische Verfahren ermittelt werden, für die Eignung als braufähiger Rohstoff für die Mälzung analysiert werden (DRAWERT, 1984; NARZISS, 1976; PALMER, 1989). Braugerstepartien sollen voll ausgereift, sortenrein, gesundheitlich einwandfrei (*Mykotoxine*), weder verunreinigt noch von Schädlingen befallen sein. Auswuchs oder Beschädigungen beeinträchtigen die Keimfähigkeit, die im Mälzungsprozess essentiell ist. Neben dem Proteingehalt und dem Gehalt an Zellwandbestandteilen beeinflusst die Endospermstruktur die Braueigenschaften. Der Proteingehalt sollte nicht über 11,5 % liegen, um negative Auswirkungen auf die Lagerstabilität und die Klarheit des Bieres zu vermeiden. Der Extraktgehalt, der im Sinne einer rohstoffsparenden Verarbeitung möglichst hoch sein soll, steht im Zusammenhang mit der Kornausbildung, die ihrerseits über das Tausendkorngewicht, das Hektolitergewicht und die Sortierung beschrieben werden kann. Wünschenswert ist ein hoher Vollgersteanteil, d. h. ein hoher Anteil der Kornfraktion mit Siebsortierung > 2,5 mm.

Für den Landwirt sind neben dem Feuchtigkeitsgehalt der Proteingehalt und die Sortierung von von besonderem Interesse, zumal diese Parameter in der Regel den Auszahlungspreis bestimmen.

2.1.3 Umwelteinflüsse

Nach SCHELLING (2000) werden die den Ertrag und den Eiweißgehalt bestimmenden Assimilat- und Stickstoffverlagerungsvorgänge sowie die physiologischen Prozesse bei der Kornfüllung maßgeblich von Umweltfaktoren beeinflusst. Der Autor diskutiert die Bedeutung und Wirkung der wichtigsten Umwelteinflüsse wie Temperatur, Wasserversorgung, Luftfeuchtigkeit, Strahlung sowie das damit zusammenhängende Auftreten von Anomalien und Pflanzenkrankheiten.

Übermäßig hohe Temperaturen, v. a. um das Blütestadium, wirken sich negativ auf den Kornertrag und die Qualität der Gerste aus (CHMIELEWSKI, 1998; EAGLES et al., 1995; SAVIN et al., 1997; SAVIN & NICOLAS, 1996). Zu dieser Thematik wurden viele Untersuchungen an Weizen durchgeführt, trotzdem gehen CHOWDHURY & WARDLAW (1978) davon aus, dass die Temperaturverhältnisse auf Gerste in ähnlicher Weise wirken. Der Ertragsrückgang wird je 1 °C Temperaturanstieg über einer Tagesmitteltemperatur von 15 °C auf 3 - 4 % geschätzt (WARDLAW et al., 1989). Die geringeren Ernteerträge resultieren aus den höheren Veratmungsverlusten, die zu geringeren Nettphotosyntheseraten führen. Für die Ertragsbildung sind hohe Temperaturen vor allem deshalb von Interesse, weil sie eine Verkürzung der Kornfüllungsphase bewirken.

Die Wasserversorgung und die Auswirkungen von Trockenstress werden von HSIAO (1973) und MATSUDA & RAYAN (1990) ausführlich diskutiert. Mit dem Auftreten von Trockenstress sind teilweise erhebliche Ertragsminderungen verbunden (DE RUITER & BROOKING, 1994). DOORENBOS & KASSAM (1979) zeigen Möglichkeiten zur Quantifizierung der Ertragseinbußen durch Trockenstress auf. Die Auswirkungen von Trockenstress vor und nach der Blüte bewirken in der Regel eine verminderte Biomasseakkumulation, ein verändertes Masseverhältnis von Wurzel zu Spross, einen geringeren Blattflächenindex und eine kleinere Anzahl an Ertragsorganen je Flächeneinheit.

Andere Umwelt- bzw. Witterungsfaktoren, wie die Luftfeuchtigkeit (CHMIELEWSKI, 1998) und die Effekte unterschiedlicher Einstrahlungsintensitäten (GRASHOFF & D'ANTUONO, 1997) werden berichtet.

Die genannten Einflussfaktoren wirken im Verbund auf den Bestand ein und sind aufgrund der entstehenden Interaktionen schwer quantifizierbar (DE RUITER & BROOKING, 1996). Untersuchungen von HÜNTING et al. (2003) liefern Hinweise auf die Wichtigkeit der Einzelfaktoren für die Ertragsvorhersage in Abhängigkeit der phänologischen Stadien.

2.2 Landnutzungsklassifikation

Die Abschätzung des Ernteaufkommens an Sommergerste in definierten Anbaubereichen setzt die Kenntnis des Anbauumfangs voraus. Die Satellitenfernerkundung bietet die Möglichkeit einer großräumigen Erfassung der Landbedeckung bzw. Landnutzung. Ein Anwendungsschwerpunkt hochauflösender Satellitendaten ist die Erkennung und die Ermittlung des Anbauumfangs von Kulturarten (RELIN, 1996).

Die Erkennung von Sommergerste stellt aufgrund ihrer morphologischen Ähnlichkeit zu anderen Getreidearten eine besondere Herausforderung in der Landnutzungsklassifikation dar. In der Literatur werden nur wenige Untersuchungen zum Thema Sommergersten-Klassifikation beschrieben, häufig werden mehrere Getreidearten in einer Landnutzungsgruppe zusammengefasst, ohne eine genauere Differenzierung vorzunehmen (ERICKSON, 1984; JEWELL, 1989; MAC DONALD & HALL, 1980). Es sind keine Untersuchungen zur Klassifikation von Braugerste bekannt. In Deutschland wird für Brauzwecke zwar überwiegend Sommergerste verwendet (SCHILL MALZ, 2002; SCHILL MALZ, 2003), abzuschätzen bleibt jedoch weiterhin der Teil an Sommergerste, der für Futterzwecke verwendet wird.

Die in der Literatur berichteten Klassifikationsgenauigkeiten schwanken je nach Fruchtartenzusammensetzung des Untersuchungsgebietes und der Datengrundlage beträchtlich. PESTEMALCI et al. (1995) konnten anhand einer LANDSAT-TM-Aufnahme die Getreidefläche (Weizen und Gerste) einer Provinz in der Türkei mit einer Klassifizierungsgenauigkeit von 85 % bestimmen. Bei KÜHBAUCH et al. (1990) wird für ein Untersuchungsgebiet in der Köln-Aachener Bucht eine Klassifikationsgenauigkeit von 97 % für Winterweizen berichtet. In einem Untersuchungsgebiet in Baden-Württemberg konnte in einzelnen Jahren die Winterweizenfläche mit einer Genauigkeit in der Flächensumme von über 98 % im Vergleich zur amtlichen Statistik klassifiziert werden (MLR, 1995). Dabei wurden allerdings Zusatzdaten, wie eine digitale Ackermaske sowie eine panchromatische SPOT-Aufnahme mit 10 m Bodenauflösung, eingesetzt. Dieselben Autoren berichten andererseits von einer Klassifikationsgenauigkeit von 66 % bei Sommergerste unter ungünstigeren Rahmenbedingungen. In Südschweden konnten in verschiedenen Untersuchungsregionen anhand von multitemporalen LANDSAT-TM-Aufnahmen Klassifikationsgenauigkeiten von 40 % und 65 % für Sommergerste erzielt werden (HALL-KÖNIGES, 1990). JEWELL (1989) klassifizierte Sommergerste mit SPOT HRV in England mit Genauigkeiten zwischen 53 % und 70 %, dabei gelang jedoch keine überzeugende Unterscheidung zwischen Weizen und Gerste.

An dieser Stelle muss betont werden, dass, abgesehen von den verwendeten Zusatzdaten, den durchgeführten Felderhebungen, der vorgenommenen Datenprozessierung und den Klassifikationsmethoden, die Bedingungen der Landnutzungsklassifikationen genau und kritisch betrachtet werden müssen, wenn Klassifikationsgenauigkeiten beurteilt werden. Von diesen, im

Regelfall vorgegebenen Bedingungen hängt die erreichbare Qualität der Ergebnisse entscheidend ab: Besonders zu beachten sind in diesem Zusammenhang die Eigenschaften des eingesetzten Sensors und des Untersuchungsgebietes sowie der Aufnahmezeitpunkt und die Qualität der FE-Aufnahmen. Auf diese Aspekte gehen u. a. KÜHBAUCH et al. (1990) ein. Einige der Kriterien, welche die Klassifikationsgenauigkeit beeinflussen, stehen zueinander umgekehrt proportional in Beziehung, etwa die geometrische und radiometrische Auflösung des Sensors, womit nicht in allen Anforderungen Idealbedingungen möglich, sondern Kompromisslösungen nötig sind. Während die radiometrische Auflösung vor allem in den Anfängen der Satelliten-Fernerkundung (LANDSAT MSS) ein Problem darstellen konnte, reichen die derzeitigen Auflösungen von 8 oder mehr *bit* für die meisten Zwecke der Landbedeckungs- bzw. Landnutzungsklassifikationen aus. Wichtiger erscheint in diesem Zusammenhang die geometrische Auflösung, die in Abhängigkeit der räumlichen Strukturen des Untersuchungsgebietes und der zu identifizierenden Objekte zu sehen ist. So sind Schläge bis zu 1 ha für vergleichende Satellitenmessungen mit LANDSAT-TM als kritisch einzustufen (BACH & MAUSER, 1999). KÜHBAUCH et al. (1990) nennen im Zusammenhang mit „reinen“ Pixel (Auflösung 30 m) Mindestschlaggrößen von 0,81 - 2,25 ha (9 – 25 Pixel). COHEN & SHOSHANY (2002) reduzieren ihre Untersuchungen mit LANDSAT TM auf Schläge über 1 ha Ausdehnung. Das Problem der geometrischen Auflösung stellt sich differenziert dar: Sind die landwirtschaftlichen Strukturen (Schlaggrößen) groß, kann mit einer relativ niedrigen räumlichen Auflösung operiert werden, liegen dagegen kleinräumige Strukturen vor, muss die geometrische Auflösung dieses Manko ausgleichen. Auch die zeitliche Auflösung bzw. die theoretische Wiederkehrrate eines Satelliten ist eng verbunden mit der geometrischen Auflösung, das heißt, dass bei hoher räumlicher Auflösung in der Regel relativ weniger Aufnahmen zur Verfügung stehen, da ein kleinerer Ausschnitt der Erdoberfläche abgebildet wird. Dazu kommt, dass die tatsächliche zeitliche Auflösung bei optischen Sensoren von den Witterungsbedingungen abhängt (Wolkenbedeckung) und sich dadurch gegenüber der theoretischen zeitlichen Auflösung deutlich verschlechtern kann. So stammen beispielsweise die 32 LANDSAT-ETM+ Szenen zur Erstellung von CORINE *land cover* Deutschland 2000 aus diesem Grund aus 3 Vegetationsperioden (KEIL et al., 2002). Für Klassifikationszwecke ist zudem die spektrale Auflösung des Sensors von Bedeutung. Je mehr spektrale Kanäle zur Verfügung stehen, desto bessere Ergebnisse können in der Fruchtartenklassifikation erzielt werden (TOULIOS & TOURNAVITI, 2003). Eine besonders hohe spektrale Auflösung ist beispielsweise notwendig, um den Hauptwendepunkt eines Vegetationsbestandes im Rot/Infrarot-Anstieg präzise zu lokalisieren, womit Rückschlüsse auf die Vitalität des Bestandes möglich sind (BOOCHS et al., 1990).

Hinsichtlich der Eigenschaften des Untersuchungsgebietes sind dessen topographische Charakteristiken zu beachten. Flache Gebiete erlauben einfacheres Klassifizieren als stärker reliefierte Gelände. Auch in Verbindung mit der tatsächlichen zeitlichen Auflösung sind die klimatischen Verhältnisse zu sehen, die für die optische Fernerkundung beispielsweise in den Tropen oder in maritim geprägten Klimaten problematisch sein können (Wolkenbedeckung). Wie

zahlreiche Untersuchungen zeigen, wird die Klassifizierung von Landbedeckungen bzw. Landnutzungen in Gebieten mit monoton ausgeprägtem Kulturenmuster erleichtert (BAN & HOWARTH, 1999; KÜHBAUCH et al., 1990; MÜLLER, 1989). Auch der Aufnahmezeitpunkt hat eine entscheidende Wirkung. So konnten beispielsweise die mit Wintergerste bestandenen Flächen mittels LANDSAT-TM in einer Untersuchungsregion in der Köln-Aachener Bucht am 1. August besonders gut erfasst werden, da die Kultur im Gegensatz zu anderen bereits abgeerntet war und das relativ deutliche Bodensignal genutzt werden konnte (KÜHBAUCH et al., 1990; MÜLLER, 1989). Fördernd auf eine hohe Klassifikationsgenauigkeit wirkt sich ein hoher Anteil der untersuchten Klasse/n an der Landbedeckung aus. Flächenmäßig dominierende Kulturen können in der Regel besser erfasst werden. Letztlich hängt die theoretisch erreichbare Klassifikationsgenauigkeit auch davon ab, wie weit die Differenzierung in die Tiefe geht, z. B. ob die Klassifikationsklassen aus Gruppen einzelner Kulturarten (z. B. „kleinkörniges Getreide“) oder aus Einzelkulturen (z. B. Sommergerste) bestehen. Kulturen mit spektral ähnlichen Signaturen werden in manchen Untersuchungen auf eine bestimmte eingeschränkt oder fusioniert, um Verwechslungen zu vermeiden (BARBOSA et al., 1996; COHEN & SHOSHANY, 2002; JEWELL, 1989).

Da sich viele Untersuchungen hinsichtlich Landnutzungsklassifikationen auf eine oder mehrere der günstigen Bedingungen stützen, werden die Fähigkeiten der Fernerkundung unter ungünstigeren Bedingungen oft überschätzt. So weist BARTHOLOME (1988) darauf hin, dass es in einigen Regionen nahezu unmöglich ist, zwischen verschiedenen Fruchtarten zu unterscheiden, wenn die agronomischen Charakteristiken, wie im Falle von Getreide, sehr ähnlich sind.

Neben dem direkten spektralen Informationsgehalt von Fernerkundungsdaten können darauf basierend Bestandeseigenschaften abgeleitet werden, die in der Klassifikation von Sommergerste hilfreich sind. Bodennahe Untersuchungen dazu wurden von MÜLLER (2000) und von KLEMAN & FAGERLUND (1987) mittels spektral hochauflösender bodennaher Radiometer durchgeführt. Eine häufig eingesetzte Größe, die direkt zur Zustandsbeschreibung von Fruchtarten genutzt wird und indirekt zur Klassifikation verwendet werden kann, ist der NDVI (ROUSE et al., 1974). Der NDVI (*Normalized Difference Vegetation Index*) berechnet sich aus den Reflexionen des roten (ρ_R) und infraroten (ρ_{NIR}) Spektralbereiches und kann theoretisch Werte zwischen -1 und $+1$ annehmen.

$$NDVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R} \quad [1]$$

BÜKER (1992) nutzte diese Größe zur Zustandsbeschreibung von Winterweizenbeständen. Der berechnete NDVI einer Fernerkundungsaufnahme stellt ein Maß für die Vitalität der beobachteten Vegetation dar (HATFIELD, 1983; IDSO et al., 1978; TUCKER & HOLBEN, 1980) und kann daher in verschiedenen phänologischen Stadien von unterschiedlicher Aussagekraft sein. Die Kenntnis des NDVI für verschiedene Fruchtarten sowie in verschiedenen Phasen der Vegetationsperiode macht diese Größe zu einem wertvollen Instrument beim Einsatz von

wissensbasierten Klassifikationsregeln. Obwohl der NDVI in der Fernerkundung seit ca. 3 Jahrzehnten erfolgreich eingesetzt wird (JENSEN, 2000), wurden auch Defizite aufgezeigt (GOWARD et al., 1991; QI et al., 1995). So können NDVI-Instabilitäten u. a. aufgrund von veränderter Bodenfeuchtigkeit, atmosphärischen Bedingungen und BRDF-Effekten (siehe Kapitel 4.1.2) auftreten.

2.3 Prognosemodelle

2.3.1 Prognosemodelle - Literaturübersicht

Modelle sind Vereinfachungen der realen Komplexität und sind somit Abbilder real existierender Phänomene. Die Modellierung erlaubt die Simulation von Prozessen, die anhand weniger Abbildungen der Wirklichkeit nachgezeichnet werden können. Einen Überblick über die vorhandenen Modelle für die Geo-Simulation ist beschrieben bei MANDL (1998; 2000). Bei Verwendung von Geoinformationssystemen kann in Modellen die räumliche Komponente Eingang finden, wonach die Prognose nicht mehr punktförmig, sondern flächendeckend durchgeführt werden kann. Für die Verrechnung von räumlichen Daten wurden spezielle Methoden entwickelt, wie das sogenannte „*cartografic modelling*“ (TOMLIN, 1990).

Eine Kategorisierung der vorhandenen Modelle für das Pflanzenwachstum oder die Ertragsbildung ist schwierig, zumal Kennzeichen einer Modellkategorie häufig in mehreren Modellkategorien gefunden werden können. Bei der folgenden Einteilung in grobe Kategorien können deshalb Mischformen vorkommen.

Deterministische Modelle:

Diese Modelle beschreiben die physikalischen, chemischen und physiologischen Prozesse der Pflanzenentwicklung, indem messbare Eingabeparameter in definierten Zeitintervallen in das Modell eingehen und Wachstumsprozesse durch mathematisch definierte Beziehungen, welche Wachstumsprozesse beschreiben, simuliert werden. Dabei kann das Zeitintervall in relativ kleinen Einheiten gewählt werden, etwa in Stunden oder Tagen. Anhand mathematischer Zusammenhänge werden Wachstumsprozesse simuliert, womit die Berechnungen exakt nachvollziehbar und wiederholbar werden. Bevorzugt eingesetzt werden diese Modelle in kleineren räumlichen Einheiten, z. B. auf Feld- oder Schlagniveau.

Zu deterministischen Modellen gibt es eine Vielzahl von Beispielen, einen Überblick geben ENGEL & BALDIOLI (1993). Unter anderem arbeitet das WOFOST-Modell, das beim MARS-Programm der EU (*Monitoring Agriculture with Remote Sensing*) eingesetzt wird, mit diesem Ansatz (SUPIT et al., 1994). Andere Beispiele dazu gibt es speziell zur Sommer- bzw. Braugerste (DE RUITER et al., 1993; GOYNE et al., 1996). Je nach Ausführung des Modells wird dabei eine

unterschiedliche Anzahl an Eingangsgrößen benötigt, häufig geht der deterministische Ansatz in die Richtung anspruchsvoller und zahlreicher Inputs. Aufgrund der umfangreichen, für den operationellen Einsatz teils kaum zu bewältigenden Datenbeschaffung, sind flächendeckende Anwendungen äußerst schwer durchführbar. LANDAU et al. (1998) beschreiben drei Wachstumssimulationsmodelle in England und raten aufgrund der ungenügenden Genauigkeit der modellierten Erträge vom operationellen Einsatz der untersuchten Modelle ab. Daneben ist die Kosten-Nutzen-Relation deterministischer Modelle ein kritischer Punkt. Anzustreben ist ein vertretbares Verhältnis zwischen dem Aufwand der Beschaffung von Inputs sowie deren Verarbeitung und der erreichten Genauigkeit der Simulation.

Sogenannte „*yield reduction models*“ gehen von Idealbedingungen und damit verbundenen Maximalerträgen aus, die sich entsprechend dem Auftreten von Stresssituationen reduzieren. Der Ansatz von DOORENBOS & KASSAM (1979) wurde für die FAO entwickelt und wird in der Literatur häufig aufgegriffen (REYNOLDS et al., 2000; RUDORFF & BATISTA, 1990). Er zielt darauf ab, durch eine einfache Beziehung zwischen der aktuellen und potentiellen Evapotranspiration zur aktuellen und potentiellen Ernte bzw. Biomasse die aktuelle Ernte abzuschätzen.

$$\left(1 - \frac{Y_a}{Y_m}\right) = k_y \left(1 - \frac{ET_a}{ET_p}\right) \quad [2]$$

Y_a ist die aktuelle Ernte, Y_m die maximal mögliche Ernte, k_y wird als *yield response factor* bezeichnet und stellt einen Skalierungsfaktor dar, ET_a die aktuelle Evapotranspiration und ET_p die maximale oder potentielle Evapotranspiration.

Y_a ist, nach Umformung der Gleichung [2]

$$Y_a = Y_m \left[1 - k_y \left(1 - \frac{ET_a}{ET_p} \right) \right] \quad [3]$$

Aufbauend auf diesem für die FAO entwickelten Modell entstand das AEZ-Modell (*agro-ecological zone*), das so modifiziert wurde (DEMIRCAN, 1995), dass es mit täglichen Datensätzen eingesetzt werden kann. Das AEZ-Modell berechnet den maximalen Ertrag eines Pflanzenbestandes, dessen Wachstum nicht durch den Mangel an Wasser oder Nährstoffen oder durch Schädlinge begrenzt wird. Das Ertragsmodell ist für den Einsatz in unterschiedlichen geographischen Regionen und für verschiedene Vegetationsarten ausgelegt und wurde u. a. für Ertragsprognosen in Baden-Württemberg verwendet (BACH & MAUSER, 1999). Das Modell geht in 2 Schritten vor: Zunächst wird, basierend auf meteorologischen Daten (Temperatur und Bewölkung, und damit indirekt Strahlung) die potentielle Biomasseproduktion eines Standardbestandes mit optimaler Blattflächenentwicklung berechnet. Ausgehend von tabellierten, empirisch erhobenen täglichen Produktionsraten für eine bestimmte Kultur wird diese der

Bewölkungssituation eines jeden Tages angepasst. In einem zweiten Schritt wird diese potentielle Biomasseproduktion durch multiplikative Faktoren reduziert und an die Situation eines realen Pflanzenbestands unter optimalen Wasser- und Nährstoffverhältnissen angepasst. Die Reduktionsfaktoren berücksichtigen Respiration und aktuelle Blattflächenentwicklung, d. h. hier geht der Blattflächenindex bzw. *Leaf Area Index* (LAI) in die Modellierung ein. Schließlich kann über einen Ernteindex der Kornertag errechnet werden. Der eingehende LAI bestimmt den Korrekturfaktor für die Blattflächenentwicklung nicht einheitlich über den gesamten Modellierungszeitraum, sondern je nach absoluter Größe des LAI unterschiedlich. An dieser Stelle bietet sich ein Ansatz, in unregelmäßigen Zeitabschnitten verfügbaren Fernerkundungs-Informationen (FE-Informationen) in das Modell zu integrieren. Der LAI kann dazu aus FE-Aufnahmen bestimmt werden, womit Ursachenfaktoren und Wirkungsfaktoren kombiniert werden.

Empirisch-statistische Modelle:

Diese Modelle beruhen auf statistischen Gesetzmäßigkeiten von historischen Umweltparametern. Anhand langjähriger Zeitserien werden Gesetzmäßigkeiten mittels statistischer Analysen (z. B. anhand von einfachen oder multiplen Korrelationsanalysen) untersucht, brauchbare Zusammenhänge identifiziert und in die Zukunft projiziert. Die Qualität der Prognose ist von mehreren Kriterien abhängig (SCHELLING, 2000): Zunächst wird die Wahl der Untersuchungsparameter getroffen, welche nach sachlogischen oder statistischen Kriterien ausgewählt werden können. Die Anzahl der möglichen Modelleingangsparameter unterliegen statistischen und praktischen Beschränkungen (FAHRMEIR et al., 1996). Bei hoher Anzahl von Modelleingangsparametern muss berücksichtigt werden, dass die Anzahl der Modellvariablen unterhalb der Anzahl der Beobachtungsjahre liegen muss. Bei der Selektion der Eingangsparameter können verschiedene Methoden zum Einsatz kommen (*forward, backward, step by step selection*). Die Auswahl der Eingangsparameter unterliegt statistischen Grenzwerten, die frei gewählt werden können (Irrtumswahrscheinlichkeiten). Werden sehr scharfe Selektionskriterien gesetzt, verbleiben nur wenige unabhängige Variablen im Modell und vermindern damit die Prognosegenauigkeit.

Zu beachten ist, dass bei einer multiplen Korrelationsanalyse nicht zwingend kausale Zusammenhänge zwischen Eingangsgrößen und erklärter Prüfgröße bestehen müssen. Unter Umständen werden Zusammenhänge durch Eingangsgrößen erklärt, die mit der Prüfgröße kausalanalytisch überhaupt nichts zu tun haben.

Mit empirisch statistischen Modellen wurde eine Vielzahl von Arbeiten erstellt (BAIER, 1977; CHMIELEWSKI, 1998; HANUS, 1969; HANUSS, 1973; SCHELLING, 2000; WILLIAMS et al., 1975). Einige Modelle basieren nur auf Witterungsparameter, andere berücksichtigen zusätzlich Informationen bzgl. des Bodens und der Topographie. Die genannten Anwendungen kommen gänzlich ohne Fernerkundungsdaten aus. Auch speziell Braugerste war Gegenstand von empirisch-statistischen Modelluntersuchungen (KLOß, 1987).

Spektrometeorologische Modelle:

Unter diesem Begriff werden Modelle verstanden, die sowohl spektrale Informationen (z. B. Fernerkundungsdaten) als auch klassische agrarmeteorologische Daten verarbeiten. Häufig tritt in der Literatur auch der Begriff der „**semi-empirischen Modelle**“ auf. Dabei wird dem Umstand Rechnung getragen, dass es sich bei diesen Modellen um eine Mischform der deterministischen und empirisch-statistischen Modelle handelt.

Neben den am Boden erfassten spektralen Daten können die spektralen Daten auch aus Fernerkundungsdaten oder Luftaufnahmen stammen. Die fernerkundlich erfassten Daten können sowohl als Eingangsgrößen für agrometeorologische Modelle verwendet werden, als auch als Information zur Schätzung der Anbaufläche. Ein weit bekanntes Beispiel war das LACIE Projekt (*Large Area Crop Inventory Experiment*), (ERICKSON, 1984; MAC DONALD & HALL, 1980). Viele Applikationen arbeiten bei diesen Modellen mit räumlich grob auflösenden, aber zeitlich hoch aufgelösten NOAA-AVHRR-Daten (BOCHENEK, 2000; GROTEN, 1993; ILLERA et al., 2000; KUITTINEN et al., 2000; MASELLI et al., 2000; SEILER et al., 2000; UNGANAI & KOGAN, 1998), weniger häufig werden höher aufgelöste LANDSAT bzw. IRS-LISS Aufnahmen verwendet (DUBEY et al., 1994). Bei diesen Modellen wird ein linearer Zusammenhang zwischen einem bestimmten Vegetationsindex (VI) und dem Ertrag (Y) ausgenutzt (HATFIELD, 1983). Häufig werden geografische Gewichtungen für den Vegetationsindex eingebaut, welche die Korrelationen verbessern sollen (GENOVESE et al., 2001; HAMAR et al., 1996; QUARMBY et al., 1993). Von MANJUNATH et al. (2002) wurden Niederschlagsdaten mittels multipler Regression integriert, wodurch die Prognosegenauigkeit erhöht wurde. Die Korrelationen können zu bestimmten festgelegten festen Zeitpunkten aber auch über bestimmte Zeiträume (Integration des VI über diesen Zeitraum) errechnet werden, wobei die Wahl des Zeitraumes für die Signifikanz des Zusammenhanges ausschlaggebend ist. Ein Modell, das verstärkt Felderhebungen in der Erntephase einbindet, verbindet Stichproben erhobener Felderträge mit Fernerkundungsdaten und kommt daraus über Regressionen zu einer Vorhersage (MURTHY et al., 1996). Hohe Wiederholraten von Sensoren bedingen naturgemäß eine grobe Auflösung, so z. B. bei NOAA-AVHRR. Um dieses Problem zu lindern, können lineare spektrale Entmischungsmethoden (*linear spectral unmixing*) eingesetzt werden, die auf die eigentlichen spektralen Reflexionen der Beobachtungskultur schließen lassen (FAIVRE & FISCHER, 2002; FISCHER, 1994). Liegen Aufnahmen, wie häufig witterungsbedingt, nicht zum gewünschten Zeitpunkt vor, z. B. zum Zeitpunkt des maximalen VIs, an dem Korrelationen zwischen VI und Ertrag besonders signifikant sind, können die vorhandenen Aufnahmen auf diesen Zeitpunkt normalisiert werden (DADHWAL & SRIDHAR, 1997; ECKERT & KELLENBERGER, 2001; PATEL et al., 1991; SHARMA et al., 1993).

Eine Sonderform der spektrometeorologischen Modelle stellen Modelle dar, die aus FE-Aufnahmen abgeleitete Größen während des Simulationszeitraumes dazu nutzen, Zustandsgrößen der Modelle anzugleichen. Erste Beschreibungen dieser Möglichkeiten wurden bei ARKIN et al. (1976), VANDERLIP & ARKIN (1977) und WIEGAND (1986) genannt. Einen Überblick über die Möglichkeiten geben DELÉCOLLE et al. (1992) und MOULIN et al. (1998). WIEGAND et al. (1979) weisen darauf hin, dass spektrale Daten am besten in Verbindung mit Modellen, die physiologische Prozesse simulieren können, genutzt werden, wobei sich beide Komponenten ergänzen können. Untersuchungen zu diesen kombinierten Modellen wurden von mehreren Autoren beschrieben und durchgeführt (ATZBERGER, 1997; MAAS, 1988a; MAAS, 1988b). ARKIN et al. (1977) erkannten die Möglichkeit, Zustandsvariablen des Modells zu ersetzen bzw. zu aktualisieren und schufen das Konzept eines „**spektro-physiologischen**“ Modells, welches Fernerkundungsdaten nutzen konnte. Genutzt wurde später eine Aktualisierungstechnik im Modell SORGF zur Prognose von Hirse (MAAS & ARKIN, 1978), allerdings handelte es sich dabei um eine Aktualisierung durch Felddaten. Die Hauptschwierigkeit des „*Updating*“ lag in der hohen Anzahl an Variablen, auf die das Modell beruhte. Andere Autoren (BRAKKE & KANEMASU, 1979) nutzten aus FE-Aufnahmen (LANDSAT MSS) modellierte LAI-Tageswerte, um Winterweizenerträge zu schätzen. Dabei kamen sie auf Korrelationskoeffizienten von 0,81 zwischen geschätztem und beobachtetem Ertrag. Die Grenzen für den operationellen Einsatz wurden jedoch aufgezeigt und die geringe Frequenz der Fernerkundungsbeobachtungen bemängelt (KANEMASU et al., 1985). DELÉCOLLE & GUÉRIF (1988) beschrieben eine Technik, um Fernerkundungsdaten in das Winterweizenmodell AFRCWHEAT zu integrieren. Die LAI-Eingabewerte werden aus einem statistischen Modell abgeleitet, das von der Temperatur bestimmt wird und das an unregelmäßige Beobachtungen angepasst wird. MAAS (1988b) beschrieb eine Methode, die Fernerkundungsdaten in ein Pflanzenwachstumsmodell integriert. Dabei wird anhand einer iterativen Annäherungstechnik eine Startgröße der Modellsimulation so angepasst, dass der simulierte LAI bestmöglich an den unregelmäßig aus Fernerkundungsdaten beobachteten LAI angepasst wird. Eine Validierung mit 37 Hirsefeldern in Texas zeigte, dass sich der Gesamtertrag von 31 % Unterschätzung ohne Einbezug von Fernerkundung auf 2 % Überschätzung verbesserte, wenn LANDSAT-Daten genutzt wurden. Dies führte schließlich zur Entwicklung des Modells GRAMI, ein Prognosemodell, das Fernerkundungsaufnahmen zur Aktualisierung seiner Zustandsgrößen einbezieht (MAAS, 1992). Ein ähnlicher Ansatz wurde für die Zuckerrübe angewandt (BOUMAN, 1992), um das Modell SUCROS für FE-Daten zu adaptieren.

Grundsätzlich bieten sich mehrere Möglichkeiten, um abgeleitete FE-Informationen in ein Modell zu integrieren (DELÉCOLLE et al., 1992; MOULIN et al., 1998):

- (1) Direkte Verwendung einer aus FE-Aufnahmen abgeleiteten Variable im Modell.
- (2) Aktualisierung einer Zustandsvariable des Modells (z. B. LAI), abgeleitet aus Fernerkundungsdaten.
- (3) Sogenannte Re-Initialisierung des Modells, d. h. die nachträgliche Berichtigung einer Variable, die als Start-Variable angenommen wurde, und damit verbunden die Berichtigung der gesamten Simulation ab diesem Zeitpunkt.
- (4) Sogenannte Re-Kalibrierung des Modells, d. h. die Berichtigung von Modell-Parametern, um eine Übereinstimmung von Simulation und FE-Beobachtung zu erreichen.

Der Unterschied der beiden letztgenannten Möglichkeiten liegt in der Definition der geänderten Größen. Parameter sind Größen, die über die Simulationszeit hinweg konstant bleiben. Häufig handelt es sich dabei um natürliche Konstanten (z. B. Solarkonstante). Zustandsgrößen (*state variables*) beschreiben den Zustand wichtiger Elemente im Gesamtsystem zu einem bestimmten Zeitpunkt. Diese können sich, ausgehend von Startwerten, im Verlauf der Simulation ändern (z. B. LAI).

Viele einfache Modelle stützen sich auf die unter Punkt (1) beschriebene Methode. Die Substitution einer Modellgröße mit einer fernerkundlich abgeleiteten, wie unter (2) beschrieben, erfolgt bei einer Adaption des Modells CERES-Wheat (BARNES et al., 1997). Die unter Punkt (3) und (4) beschriebene Strategie, die Verwendung von fernerkundlich gewonnenen Parametern innerhalb des Modellierungszeitraumes zur Angleichung der Simulation, wird im Englischen auch als „*within season calibration*“ bezeichnet. Modelle wie GRAMI nutzen diese Eingabegrößen zur Optimierung ihrer Simulationsergebnisse (MAAS, 1993). Dabei handelt es sich um mathematische Operationen, die schließlich zu einer Minimierung der Differenzen zwischen beobachteten und simulierten Zustandsgrößen führen sollen. Ein ähnlicher Ansatz wird beim CAMPOS-Modell (*Cereal Accumulation Model progressively optimised by satellite*) bzw. CEREAL-YES-Modell (*cereal yield estimation system*) (DE KOEIJER et al., 2000; DENORE et al., 2000; WILLIAMS et al., 2002) verwendet, womit in einer spanischen Region u. a. der Sommergersteertrag modelliert wurde.

Als ein Beispiel eines semi-empirischen oder spektrometeorologischen Modells sei der Ansatz von MONTEITH (1977) genannt, der später an den Gebrauch von radiometrischen Daten adaptiert wurde (KUMAR & MONTEITH, 1981). ASRAR et al. (1985) verwendeten diesen Ansatz in ihrer Biomasse-Schätzung in Verbindung mit Fernerkundungsdaten. Dabei wird davon ausgegangen, dass für eine gesunde Pflanze, die ausreichend mit Wasser und Nährstoffen versorgt ist, die Nettphotosynthese und somit die Biomasseproduktion proportional zur Höhe der absorbierten photosynthetisch aktiven Strahlung (APAR) ist. Wie auch andere Autoren zeigen BARET &

GUYOT (1991), dass die absorbierte PAR (APAR) über multispektrale Messungen bestimmt werden kann. Die verwendete Grundformel (MONTEITH, 1977) lautet:

$$M = \sum_{i=1}^n \varepsilon_i \varepsilon_a \varepsilon_c S C \quad [4]$$

M ist die gesamte trockene Biomasse, n ein Zeitindex (z. B. Anzahl Tage), ε_i die Fraktion der PAR am gesamten elektromagnetischen Spektrum, ε_a die Fraktion der absorbierten PAR (häufig auch fAPAR genannt), ε_c der photochemische Effizienzfaktor (*light use efficiency factor*), S die gesamte solare Einstrahlung [$\text{J m}^{-2}\text{d}^{-1}$] und C ein Pflanzenstressindex.

ε_i ist dimensionslos und nahezu unabhängig von den atmosphärischen Bedingungen, es wird in der Literatur häufig als Konstante von 0,48 angenommen (VARLET-GRANCHER et al., 1982).

ε_a ist dimensionslos und drückt anteilmäßig das aus, was an PAR absorbiert werden kann. ε_a schwankt zwischen Werten von 0 für nackten Boden bis zu Werten von 0,95 für eine geschlossene grüne Pflanzendecke. Somit hängt ε_a von den optischen Eigenschaften der Pflanzendecke ab und kann aus Messungen der Reflektanz abgeleitet werden (LOBELL et al., 2002).

Der photochemische Faktor ε_c ist dimensionslos und gibt das Verhältnis an, mit dem absorbierte PAR in Trockenbiomasse umgewandelt wird. Je nach Autor ist dieser Faktor entweder relativ konstant für eine bestimmte Kulturpflanze (MONTEITH, 1977) oder (z. B. für Winterweizen) er hängt ab von Kulturmaßnahmen und phänologischem Stadium (ASRAR et al., 1984b). Der Faktor ε_c ist für C3 und C4-Pflanzen generell unterschiedlich hoch angesiedelt.

Der Faktor C kann dazu genutzt werden, um Pflanzenstress in das Modell zu integrieren. C kann z. B. Wasser- und/oder Temperaturstress sein (DAUGHTRY et al., 1983), wobei das Verhältnis von aktueller zu potentieller Evapotranspiration verwendet werden kann (JACKSON, 1982). Sind diese Daten nicht vorhanden, könnten in einem einfachen Ansatz und bei genügender zeitlicher Auflösung die wasserempfindlichen Spektralbereiche aus FE-Aufnahmen herangezogen werden, wie beispielsweise die LANDSAT-Kanäle 5 bei 1,65 μm und Kanal 7 bei 2,2 μm Wellenlänge.

Neben biotischem Stress könnte eine räumliche Differenzierung auch durch abiotische Faktoren stattfinden, sofern das Modell eine räumliche Differenzierung ermöglicht. Dafür bietet sich z. B. ein Höhenmodell oder die Integration flächiger bodenkundlicher Informationen an. Eine auf eine bestimmte Höhe oder Boden normierte Simulation lässt sich, aufbauend an die konkrete Höhe bzw. an die konkreten Bodenverhältnisse, anpassen. Damit können die Ansprüche von MÜLLER (2000) erfüllt werden, die in ihrer Arbeit auf die Berücksichtigung von Höhe und Boden hinweist. Auch andere Autoren (ASRAR et al., 1984a) erklären, dass eine Erntevorhersage auf Basis der PAR alleine nicht gewährleistet ist.

2.3.2 Problematiken der Prognosemodelle

Grundsätzlich stellt sich die Frage nach der Verfügbarkeit der Eingabedaten sowie nach der Qualität und Zuverlässigkeit der Daten. In einigen Fällen sind experimentell erhobene Daten notwendig, die nicht immer beschafft werden können. Dann müssen Erfahrungswerte oder Werte aus der Literatur entnommen werden, die mit Unsicherheiten verbunden sind. In diesen Fällen müssen die Prognoseergebnisse mit besonderer Sorgfalt beurteilt werden.

Viele Anwendungen von spektrometeorologischen Modellen zielen auf die Extraktion des LAI oder der absorbierten PAR als bestimmende Faktoren für die Modellierung ab. Sofern das Modell weder auf Erfahrungs- noch auf Literaturwerte zurückgreift, stellt die Gewinnung von experimentell erhobenen Daten unter Umständen ein Problem dar. Die Erhebungen sind arbeitsaufwändig und die Ergebnisse müssen über entsprechende Messinstrumente gewonnen werden.

Häufig wird der NDVI als Vegetationsindex eingesetzt. Obwohl es eine Vielzahl weiterer VI gibt, sind grundlegende Zusammenhänge, wie der folgende, für die meisten VI vergleichbar. Der Zusammenhang des grünen LAI und dem NDVI ist exponentiell und wird durch die Formel

$$LAI = a + b \cdot NDVI^c \quad [5]$$

repräsentiert, wobei a , b und c pflanzenspezifische Faktoren sind. Dieser Zusammenhang ist in der Literatur häufig beschrieben (CLEVERS, 1989; JACKSON & PINTER, 1986; SCHELLBERG & KÜHBAUCH, 1991). Ein immer wieder auftretendes Problem bei der Nutzung dieses Zusammenhanges ist der Plateaubereich, der im höheren LAI-Bereich aufgrund der Sättigung der Reflexion auftritt. Damit verliert diese Beziehung ab einem bestimmten NDVI ihre Aussagekraft. ASRAR et al. (1984a) sprechen in Untersuchungen an Winterweizen erst ab LAI > 6 von einer Sättigung. Bei Winterweizen wird von einer linearen Beziehung zwischen NDVI und LAI bis LAI 3 berichtet (SCHELLBERG, 1990). Da Sommergerstenbestände generell schütterer als Weizenbestände sind, dürfte das Problem der Sättigung bei Sommergerste seltener auftreten als bei Winterweizen. Darauf weisen auch Untersuchungen von DEMIRCAN (1995) hin: Fünf von im Feld gemessene Gerstenbestände erreichten LAIs von 1 bis 5, wobei nur ein Bestand LAI 5 erreichte, die restlichen Bestände blieben unter LAI 3,9. Ein von diesem Autor entwickeltes Modell geht im Besonderen auf die Problematik der Sättigung im Zusammenhang von LAI und Biomasse ein. Durch die Verknüpfung des LAI mit Größen für die Wachstumsdauer und für die Phänologie soll der Effekt der Sättigung des NDVI ab einem höheren LAI abgeschwächt werden.

Andere Ansätze verwenden die absorbierte photosynthetisch aktive Strahlung (APAR) als Eingangsgröße in die Modellierung. ASRAR et al. (1984a) hatten eine lineare Beziehung zwischen dem NDVI und der absorbierten PAR (APAR) mit einem Korrelationskoeffizienten von 0,98 gefunden ([6]).

$$NDVI = 0,087 + 0,798 \cdot APAR \quad [6]$$

SELLERS et al. (1996b; 1996a) und WIEGAND et al. (1991) beschreiben eine quasi-lineare Korrelation zwischen dem Verhältnis von absorbierter zu eingestrahelter PAR (fAPAR) auf der einen Seite und dem NDVI (NDVI zwischen dem 2-Perzentil und 98-Perzentil) auf der anderen Seite. Andere Autoren beschreiben den Zusammenhang eines VI (RVI – *Ratio Vegetation Index*, Quotient aus Infrarot/Rot) mit der fAPAR als nichtlinear und konnten die Beziehung über eine exponentielle Funktion nachvollziehen (CHRISTENSEN & GOUDRIAAN, 1993). Da der Zusammenhang zwischen VI und der FPAR linear oder nicht linear sein mag, könne ein flächengemittelter Wert des VI genutzt werden, um einen über eine Fläche integrierten Schätzwert für die FPAR zu gewinnen (SELLERS et al., 1992).

Bei WIEGAND (1986) ist der direkte lineare Zusammenhang des NDVI mit der Blattbiomasse von Sommerweizenbeständen unterschiedlicher Saatstärke beschrieben. Ebenso ergaben die Beziehungen zwischen einem Vegetationsindex und der Trockenmasse bzw. der Anzahl der Halme eine lineare Korrelation. Die Anzahl der Stichprobenpaare war allerdings gering, die Beprobungen wurden für Winterweizen durchgeführt und lagen im Herbst. Die Korrelationen zwischen LAI und Ertrag erreichten einen Korrelationskoeffizienten von 0,91. Hilfreiche Verbindungen zwischen der saisonalen Trockenmasseanhäufung und den Spektraldaten gibt es nur solange, wie die Blattmasse den Großteil der Biomasse bildet, also bis zum Ende der Bestockung. Danach, wenn die Halme dominant werden, sinkt der Korrelationskoeffizient, wodurch auch die Vegetationsindizes als Vorhersageinstrumente für den saisonalen Aufbau der Gesamttrockenmasse ausfallen (AASE & SIDDOWAY, 1981).

Bei Korrelationen ist in diesem Zusammenhang neben der Magnitude des grünen LAI auch die Dauer dieses Zustandes für den betrachteten Zeitraum von Interesse (HATFIELD, 1983; IDSO et al., 1978; TUCKER & HOLBEN, 1980). Diesem Umstand kann durch Integral-Bildung des LAI Rechnung getragen werden. Als Zeitspannen werden unterschiedliche Phasen genannt. AASE & SIDDOWAY (1981) berichten von besten Korrelationen zwischen spektralen Indizes und Weizenerträgen zwischen dem Schossen und der Gelbreife. Das deckt sich mit Untersuchungen, bei denen 11 Vegetationsindizes für 7 phänologische Phasen von Winterweizen analysiert wurden, unter Beobachtung höchster Korrelationswerte beim Ährenschieben (GIOVACCHINI, 1986). Andere Autoren nennen eine 5-wöchige Periode zwischen dem Schossen und der Blüte, die den höchsten Erklärungsbeitrag lieferte (TUCKER & HOLBEN, 1980). Bei Untersuchungen in Kasachstan mit zwei speziellen VI konnten fast über den gesamten Untersuchungszeitraum gute Korrelationen zwischen NOAA-AVHRR und Weizenerträgen (KOGAN, 2001). KÜHBAUCH et

al. (1991) fanden die besten Beziehungen zwischen dem Vegetationsindex und dem Kornertrag von Winterweizen ca. drei Wochen nach der Blüte.

Bei PINTER et al. (1981) werden NDVI-Summen für Weizen und Gerste vom Zeitpunkt des Ährenschiebens bis zur Reife gebildet, wobei die NDVI-Werte ab einem bestimmten Basis-Wert verwendet wurden. Somit wird neben dem Faktor der Vitalität auch der Faktor der Persistenz dieses Zustandes berücksichtigt. Ein ähnlicher Ansatz findet sich auch bei anderen Autoren (COLEMAN, 1995; QUARMBY et al., 1993). COLEMAN (1995) berichtet zudem, dass die Verwendung von beobachteten phänologischen Zeitgrenzen gegenüber fix datierten Zeitgrenzen keine Verbesserungen der Prognose ergab.

Der Einsatz von Fernerkundung sollte die Bestimmung von markanten phänologischen Stadien über spektrale Reflektanzen zulassen. Hierzu wird berichtet (HATFIELD, 1983), dass für Weizen das Maximum des VI (RVI) im Stadium des Ährenschiebens erreicht war und dass bei Erreichen der Hälfte des maximalen VI 90 % der Korneinlagerung erreicht war. Auf diese Weise ließe sich die Kornfüllungsphase bestimmen. Andere Untersuchungsergebnisse unterstützen diese Erkenntnis (MÜLLER, 2000).

Problematisch ist die flächige Erfassung der Düngung und der Pflanzenschutzbehandlung. Dazu müssten enorme Datenmengen gesammelt werden. Hierzu wurde die Auswirkung von N-Düngung auf die spektralen Eigenschaften von Gerste untersucht (JENSEN & LORENZEN, 1990). Zwischen Behandlungen mit 50 kg N ha^{-1} und 100 kg N ha^{-1} und zwischen Behandlungen mit 100 kg N ha^{-1} und 150 kg N ha^{-1} wurden bei Erreichen der maximalen Biomasse keine signifikanten Unterschiede gefunden. Beim Vergleich aller drei genannten Stickstoffstufen über die gesamte Vegetationsperiode konnten dagegen signifikante Differenzen nachgewiesen werden. Bei KLEMAN und FAGERLUND (1987) konnten deutlich unterschiedliche Werte für den RVI für unterschiedlich gedüngte Gerstenbestände nachgewiesen werden. Am Beispiel Weizen wurde gezeigt, dass der Sättigungsbereich des NDVI, der viel vitale Biomasse anzeigt, in hoch gedüngten und mit Fungiziden behandelten Varianten länger erhalten bleibt als in den weniger intensiv behandelten Beständen (KÜHBAUCH, 1999). Implizit ist im VI ein Teil des Düngungs- und Pflanzenschutzregimes abgebildet, in einheitlich bewirtschafteten Regionen muss unter Umständen die Annahme getroffen werden, dass keine signifikant unterschiedlichen Pflanzenschutzmaßnahmen angewandt werden.

DEMIRCAN (1995) hat den Zusammenhang zwischen kumuliertem LAI und der Biomasse untersucht und fand eine lineare Korrelation zwischen diesen beiden Größen mit einem Korrelationskoeffizienten von $r = 0,96$. Allerdings merkt der Autor an, dass für die Kumulation LAI-Messungen mit einer relativ hohen zeitlichen Auflösung notwendig sind. Es bestehen somit gewisse Schwierigkeiten, den kumulierten LAI zu bestimmen, wenn keine kontinuierlichen Messungen des LAI vorliegen.

Generell stellt sich die Frage, welcher Vegetationsindex verwendet werden soll. Jeder Vegetationsindex hat seine Stärken und Schwächen, während ein Teil die Bodenreflexion im Hintergrund einer Pflanzendecke besonders berücksichtigt, liegen bei anderen die Stärken in der Berücksichtigung atmosphärischer Effekte oder in der simplen Generierung. BARET & GUYOT (1991) haben in einem Vergleich mehrere Vegetationsindizes (VI) miteinander verglichen: NDVI (*normalized difference vegetation index*) (ROUSE et al., 1974), PVI (*perpendicular vegetation index*) (RICHARDSON & WIEGAND, 1977), SAVI (*soil adjusted vegetation index*) (HUETE, 1988) und TSAVI (*transformed soil adjusted vegetation index*) (BARET et al., 1989). Die letztgenannten 3 VI berücksichtigen v. a. den Einfluss der Bodenreflexion und eignen sich daher gut in niedrigen LAI-Bereichen. Liegt der LAI zwischen 2 und 4, zeigen alle geprüften VI ein ähnliches Verhalten, während bei höheren LAI-Werten der NDVI sich am Besten verhält, gefolgt von TSAVI, SAVI und PVI. Der NDVI hat den großen Vorteil, dass zu dessen Bestimmung neben der Messung der Reflexion keine weiteren Parameter nötig sind. PVI, SAVI und TSAVI benötigen mindestens zwei weitere Parameter zur Bestimmung der „*soil line*“, wobei diese Linie nicht immer eindeutig bestimmbar ist (DEMIRCAN, 1995). Ein weiterer VI ist der GARI (*green atmospherically resistant vegetation index*) (GITELSON et al., 1996), der den Vorteil hat, weniger stark auf den asymptotischen Sättigungsbereich der Beziehung VI zu LAI anzusprechen und atmosphärische Effekte zu berücksichtigen. Zur Berechnung des GARI sind Parameter zu bestimmen, welche die atmosphärischen Korrekturen beeinflussen. Als Inputs werden blaue, grüne, rote und infrarote Reflektanzen benötigt.

2.3.3 Voraussetzungen eines Prognosemodells

Grundsätzliche Fragen zu den Zielen und Aufgaben eines Prognosemodells für landwirtschaftliche Anwendungen werden von STEVEN & JAGGARD (1995) diskutiert. Demnach werden grundsätzliche Vorgehensweisen, die bei einem Prognosemodell zu beachten sind, in drei Kategorien eingeteilt: Prinzipien zur Klassifikation, zur Pflanzenzustandsbeschreibung und zur Identifikation von Stress in Pflanzen. Während die beiden erstgenannten Argumente in die Fruchtartenklassifikation – einem Teil des Prognosemodells - einfließen können, sind für die im engeren Sinne verstandene Ertragsprognose (Flächenertrag) die beiden letzten Punkte zu beachten.

Bevor Kriterien für die Analyse geeigneter Modelle definiert werden, sind generelle Fragen eines Prognosemodells unter besonderer Berücksichtigung der vorliegenden Zielvorgaben zu diskutieren:

1. Was soll geschätzt werden?

Geschätzt werden soll der Flächenertrag [$t\ ha^{-1}$] sowie die Flächenausdehnung von Braugerste. Die in Deutschland übliche nahezu ausschließliche Verwendung von Sommergerste für Brauzwecke lässt eine Beschränkung auf Sommergerste zu. Der für Brauzwecke geeignete Anteil von Sommergerste kann und muss über Erfahrungswerte abgeschätzt werden. Eine Abschätzung dieses Anteils scheint im Moment mit Methoden der Fernerkundung für operationelle Zwecke noch nicht verlässlich realisierbar. In der Literatur wird über Zusammenhänge zwischen Ertrag und Qualität von Braugerste berichtet (SCHELLING, 2000; SCHELLING et al., 2003a). Gute Erträge korrelieren demnach mit guter Qualität. Die hier angestrebte Prognose soll sich auf die verbindliche Vorhersage von Erträgen beschränken, obwohl ein Interpretationsspielraum für weiterführende Aussagen zur Qualität vorhanden ist.

2. Wann sollen die Prognosen vorliegen?

Die Ertrags- und Qualitätsprognosen werden von den Anwendern prinzipiell so früh wie möglich gewünscht. Unter Berücksichtigung der abnehmenden Güte einer Prognose soll der Zeitpunkt oder die Zeitpunkte der Prognosen, sofern es mehrere sind, so gewählt werden, dass ein guter Kompromiss zwischen der Qualität der Prognose und dem Abstand zur Ernte erreicht wird. Dies kann in einer mehrfachen Prognose resultieren, die gegen den Erntezeitpunkt hin fortschreitend bessere Ergebnisse erzielt.

3. Mit welcher Genauigkeit sollen die Prognosen vorliegen?

In der Literatur wird von unterschiedlichen Genauigkeiten für die Ertragsprognose berichtet, von Fehlern unter wenigen Prozenten bis hin zu Fehlern weit über 30 %. Die Genauigkeit ist u. a. vom Umfang und Aufwand des Inputs und vom Zeitpunkt der Prognose abhängig. Die angestrebte Strategie, welche mehr oder weniger aufwändig sein kann, gibt die Anforderungen an die Genauigkeit vor. Für nahe am Erntezeitpunkt gelegene Prognosen werden, in Anlehnung an die Literatur, Genauigkeiten von unter 10 % oder 15 % erwartet. Unter dem Aspekt der Praktikabilität wird eine Optimierungsstrategie insofern verfolgt, als mit möglichst wenigen Eingangsdaten möglichst hohe Trefferquoten zu erzielen sind.

4. Welche Eingabedaten sollen verwendet werden?

Die Verwendung der Eingabedaten richtet sich nach der Verfügbarkeit, dem Umfang, den Kosten und dem generellen Aufwand der Beschaffung sowie der Zeitspanne, die zwischen Anforderung und Bestellung liegt. Insbesondere soll in der vorliegenden Arbeit auch auf die günstigen Möglichkeiten der Datenbeschaffung eingegangen werden (*Free-Downloads*, etc.).

5. Welcher Aufwand für die Daten und Datenverarbeitung wird akzeptiert?

Die Kosten/Nutzen-Relation hängt eng mit der Frage der Prognosegenauigkeit und damit mit der Frage der verwendeten Eingabedaten zusammen. So können, sofern der Nutzer dies in Kauf nimmt, Abstriche an die Prognosegenauigkeit gemacht werden und dafür Gewinne in der Praktikabilität. Hier gilt es, die richtige Mischung zwischen Aufwand und Nutzwert zu finden.

6. Welche räumliche Abdeckung ist erforderlich?

Aufgrund der Konzentration des Braugerstenanbaus auf eine beschränkte Anzahl von Anbaugebieten können mehrere Regionalprognosen den Großteil des Sommergerstenaufkommens abdecken. Innerhalb dieser Anbauregionen ist eine flächendeckende Prognose erforderlich. Viele der in der Literatur beschriebenen Modelle dienen experimentellen Zwecken und sind hinsichtlich Abdeckung nur punktuell ausgelegt, sie sind somit für den operationellen Einsatz und einer damit verbundenen flächendeckenden Anwendung erst zu adaptieren. Geografische Informationssysteme (GIS), digitale Bildverarbeitung und Datenbanken stellen hilfreiche Instrumente in der Umsetzung dieser Aufgabe dar. Da die Aufgabenstellung in der Erstellung regionaler Ernteprognosen liegt und somit eine gesonderte Betrachtung jeder Untersuchungsregion erfordert, ist die Übertragbarkeit auf andere Regionen zwar nicht zwingend erforderlich, jedoch wünschenswert.

7. Ist die Prognose objektiv, transparent und reproduzierbar?

Der große Vorteil der Fernerkundung liegt neben der flächendeckenden Anwendbarkeit auch darin, eine vergleichsweise objektive, nämlich nicht auf Stichproben reduzierte Datengrundlage zu haben, womit Aussagen transparenter und reproduzierbarer werden. Gleichwohl ist anzumerken, dass in eine Prognosemodellierung auch punktuell erhobene Daten, die empirisch oder experimentell erhoben wurden, einfließen können, die flächendeckend angewandt werden und den genannten Anspruch damit relativieren. Hinsichtlich der Objektivität sind Eingangsdaten, die der subjektiven menschlichen Beurteilung unterliegen, kritisch zu beurteilen, obwohl dies nicht ausschließt, dass gemessene Daten fehlerfrei wären. Messdaten können im Laufe der vom Menschen gesteuerten Gewinnung oder Prozessierung ebenso verfälscht werden.

2.3.4 Analyse potentiell geeigneter Prognosemodelle

Die Prüfung und Bewertung der in der Literatur bekannten Prognosemodelle und Modellansätze wurde vor allem im Hinblick auf folgende Fragestellungen durchgeführt:

1. Können die Ziele der Ertragsprognose von Braugerste mit hinreichender Genauigkeit erreicht werden, welchen Beitrag kann dazu die Fernerkundung leisten?
2. Welche Erfordernisse bzgl. Art, Umfang und kontinuierlicher Verfügbarkeit von Eingangsdaten bestehen?
3. Wie hoch fällt die Trefferquote der Simulationen unter verschiedenen Bedingungen und Jahren aus?

4. Liegt eine lokale Beschränkung der Einsatzfähigkeit vor und ist eine regionalspezifische Anpassung realisierbar?
5. Ist der Einsatz unter operationellen Aspekten, wie einer ausgewogenen Kosten/Nutzen-Relation, möglich.

Grundsätzlich stellte sich zunächst die Frage, mit einem deterministischen oder einem empirisch-statistischen Prognosemodell zu operieren. Die Anzahl und Vielfalt notwendiger Eingabegrößen für deterministische Modelle ist in der Regel höher als für empirisch-statistische. Empirisch-statistische Prognosemodelle greifen dagegen auf eine geringere Datenvielfalt zurück; sie benötigen allerdings mehrjährige historische Datenzeitreihen. Das Für und Wider dieser beiden Modellarten soll noch ausführlicher beleuchtet werden:

Deterministische Modelle erfordern in der Regel LAI oder APAR als direkte oder indirekte Eingabewerte. Häufig werden auch zusätzlich notwendigen Größen, wie ein pflanzenspezifischer Extinktionskoeffizient für den exponentiellen Zusammenhang zwischen LAI und APAR und ein photochemischer Effizienzfaktor (*light use efficiency factor*), benötigt. GILLET (1997) berichtet von Extinktionskoeffizienten des exponentiellen Zusammenhanges (*Lambert-Beer'sches Gesetz*) zwischen fAPAR und LAI, die für Weizen im Bereich zwischen 0,33 und 0,67 liegen. Andere, aufwändigere deterministische Modelle benötigen eine Vielzahl von Eingangsgrößen, die nicht flächendeckend vorliegen oder nur schwer geschätzt werden können (z. B. Bodenkennwerte, Aussaattermine). Die Anwendung eines deterministischen Prognosemodells erfordert die Bestimmung eines Großteils dieser Parameter. Für die vorliegende Studie standen viele dieser Parameter nicht zur Verfügung bzw. hätten aus technischen und zeitlichen Gründen nicht gemessen werden können. Hätte man stattdessen Schätzwerte aus der Literatur für Parameter in deterministischen Modellen verwendet, wäre durch die damit verbundenen Unsicherheiten damit zu rechnen gewesen, dass die grundsätzlich durch den deterministischen Ansatz zu erwartende Genauigkeit nicht erreicht werden konnte.

Empirisch-statistische Modelle greifen auf lange Daten-Zeitreihen zurück. Neben Fernerkundungsdaten und agrarstatischen Daten können anderweitige aussagekräftige Datensätze dazugenommen werden, um die Genauigkeit der Modellierung zu erhöhen. So wurden beispielsweise Niederschlagsdaten mittels multipler Regression integriert (GROTEN, 1993; MANJUNATH et al., 2002). Die Datenbasis ist nicht genau vorgegeben wie in deterministischen Modellen, welche physiologische Wachstumsprozesse modellieren, dadurch ist eine Erweiterung der Datengrundlage auch für Eingangsgrößen ohne direkten kausalen Erklärungsbeitrag möglich.

Der empirisch-statistische Ansatz ermöglicht eine flächige Modellierung bzw. ist dafür prädestiniert: Viele der bekannten Anwendungen operieren mit grobauflösenden FE-Daten, die zwar keine Ableitung von Informationen auf Schlagebene zulassen, dafür aber weitreichende

Gebiete abdecken. Gegenüber hoch- oder höchst aufgelösten FE-Daten, die häufig in deterministischen Modellen, die auf Schlagebene ausgelegt sind, eingesetzt werden, bringt das einen massiven Kostenvorteil. Zudem ist bekannt, dass mit diesen Modellen vielversprechende Ergebnisse erzielt werden: In Polen wurde für Getreide mit einem empirisch-statistischen Ertragsmodell, angewandt auf mehrere administrative Einheiten, eine mittlere Fehlergenauigkeit von 7 % erreicht (BOCHENEK, 2000). In Burkino Faso wurden in verschiedenen Varianten von Regressionsmodellen mit NOAA-AVHRR-NDVI (7,6 km Auflösung) und Niederschlagsdaten für die Prognose von Hirseertrag Erklärungsbeiträge von 67–73 % gefunden. GENOVESE et al. (2001) konnten zeigen, dass bei Integration der CORINE-Landnutzungskarte Weizenerträge spanischer Regionen mit einem Bestimmtheitsmaß von 0,88 und einem Standardfehler von 315 kg ha⁻¹ modelliert werden konnten. Der über Regionen und Jahre gemittelte Abweichungsfehler der Prognosen lag bei 13,7 %. Ebenso in Spanien konnten ILLERA et al. (2000) bei Einbezug von meteorologischen Daten, Oberflächentemperaturen, Globalstrahlung, NOAA-AVHRR-NDVI und CORINE die Getreideerträge einer spanischen Region mit einer mittleren Abweichung von 6,3 % schätzen.

Erfahrungen der Vergangenheit haben gezeigt, dass Fernerkundungs-Ertragsprognosesysteme für den operationellen Einsatz dann gescheitert sind, wenn die FE-Daten nicht mit Sicherheit und nicht kontinuierlich vorlagen (KÜHBAUCH et al., 1998). Die Wiederkehrzeit von z. B. LANDSAT liegt zwar theoretisch bei 16 Tagen, durch die Wolkenbedeckung mit entsprechend unbrauchbaren Szenen kann sich diese Spanne jedoch drastisch erhöhen. Mit empirisch-statistischen Prognosemodellen kann auf langjährige und kontinuierliche Zeitreihen von FE-Aufnahmen zurückgegriffen werden, die zudem über hohe Wiederkehrzeiten verfügen. Damit werden die Probleme der FE-Datenverfügbarkeit (und der Wolkenbedeckung) minimiert.

Aufgrund der genannten Umstände und im Hinblick auf die erforderliche Operationalität des Prognoseverfahrens wurde dem empirisch-statistischen Ansatz der Vorzug gegeben. Die dafür notwendigen Daten konnten erhoben werden: In die Ertragsprognose gehen NOAA-AVHRR-NDVI-Maximalwertkompositen, CORINE *land cover*, meteorologische, phänologische, agrarstatistische und administrative Daten ein. Durch die Integration dieser Daten sollen die notwendigen Genauigkeitsansprüche gewährleistet werden. Gleichzeitig bleiben damit die notwendigen Voraussetzungen für die operationelle Umsetzbarkeit gewahrt (Kosten-Nutzen-Verhältnis). Der Nachteil, dass ein empirisch-statistisches Modell einer lokalen Beschränkung unterliegt und auf andere Regionen nicht transferierbar ist, wird dadurch gemildert, dass die entsprechenden Anpassungen relativ einfach und rasch durchführbar sind und dass Braugersteinbauregionen in jedem Fall eine gesonderte Betrachtung erfordern.

Die Datenbasis der Fruchtartenklassifikation stützt sich dagegen auf hochauflösende Satellitendaten, Felderhebungen, topographische Daten und Felderhebungen (*Ground Truth*).

3 Untersuchungsregion

3.1 Auswahl der Untersuchungsregionen

Die beiden Untersuchungsregionen liegen in Rheinland-Pfalz (RLP) bzw. Baden-Württemberg (BW); (Abbildung 2, 3, 4) und umfassen 2 bzw. 4 Landkreise, die der europäischen territorialen statistischen Ebene NUTS-3 entsprechen (EU, 2003). Die Auswahl der Flächen erfolgte in Zusammenarbeit mit den lokalen Behörden. Es wurden Landwirte ausfindig gemacht, die Braugerste an für die Untersuchungsregion repräsentativen Standorten anbauten und bereit waren, am vorliegenden Projekt mitzuarbeiten. Das Augenmerk wurde auf die Eigenschaften der Feldschläge gelegt, die für eine fernerkundliche Aufnahme geeignet sein mussten (Größe, Längen/Breiten-Verhältnis, keine übermäßige Steilheit, etc.). Neben Klassifikationszwecken dienten die Felderhebungen vor Ort (*Ground Truth*) der Erfassung von Kulturführungsdaten, die im Zuge der Auswertungen notwendig sein konnten. Insgesamt konnten 10 Landwirte an 10 Standorten mit insgesamt 17 Braugersteschlägen für die Kooperation gewonnen werden (Tabelle 1). Zu diesen Schlägen wurden im Jahr 2001 detaillierte Daten erhoben (Erträge, Qualität, Bestandesführungsdaten etc.).

Tabelle 1: Standorte der Untersuchungsregionen in RLP und BW

Untersuchungs- region	Standort	Standort Abkürzung	Landkreis	Landkreis Abkürzung
RLP	Steinfeld	Steinf	Südl. Weinstrasse	Süw
	Ottersheim	Ott	Germersheim	Germ
	Offenbach a. d. Queich	Off	Südl. Weinstrasse	Süw
	Insheim	Ins	Südl. Weinstrasse	Süw
	Herxheim	Herx	Südl. Weinstrasse	Süw
BW	Strassberg	Strass	Zollern-Alb-Kreis	Zak
	Spaichingen	Spaich	Tuttlingen	Tutt
	Horb	Horb	Freudenstadt	Fds
	Haigerloch	Haig	Zollern-Alb-Kreis	Zak
	Epfendorf	Epf	Rottweil	Rott




Abbildung 3: Übersichtskarte. Die Untersuchungsregionen liegen in Rheinland-Pfalz (RLP) und Baden-Württemberg (BW).




Abbildung 4: Untersuchungsgebiet RLP mit Landkreisgrenzen, Lage der phänologischen Stationen, der Klimastationen sowie der kartierten Standorte. Die Karte ist hinterlegt mit dem Ausschnitt einer panchromatischen LANDSAT ETM-Aufnahme vom 30.7.01.




Abbildung 5: Untersuchungsgebiet BW mit Landkreisgrenzen, Lage der phänologischen Stationen, der Klimastationen sowie der kartierten Standorte. Die Karte ist hinterlegt mit dem Ausschnitt einer Pseudo-Echtfarbendarstellung (3-2-1) einer LANDSAT TM Aufnahme vom 1.4.01. Der südl. Teil des Landkreises Tuttlingen wird nicht abgedeckt.

3.2 Naturräumliche Beschreibung der Untersuchungsregionen

3.2.1 Untersuchungsregion Rheinland-Pfalz (RLP)

Die Standorte liegen in der Vorderpfalz, und zwar im Nördlichen Oberrheintiefland, in den naturräumlichen Haupteinheiten „Haardtrand“ (Standort Steinfeld) sowie „Vorderpfälzer Tiefland“ (Ottersheim, Offenbach, Insheim, Herxheim). Die Zone um Steinfeld wird als „Südliche Oberhaardt“ bezeichnet und stellt den südlichsten Teil des Haardtrandes dar, der sich vor dem Ostabfall des Pfälzer Waldes in Nord-Süd-Richtung erstreckt. Geomorphologisch handelt es sich um eine Vorhügelzone des Pfälzer Waldes mit zum Rhein hin gerichteter Zertalung. Die An- und Auflagerungen sind kalkig und mergelig ausgebildete tertiäre Schichten. Hangschutt, Schotter und Sande sowie Löß und Lößlehm bilden den Abschluss der Gesteinsserien. Die Standorte Ottersheim, Offenbach, Insheim und Herxheim liegen auf der schwach hügeligen, gewässerarmen Herxheim-Offenbacher Lößplatte, die zwischen 110 und 155 m hoch liegt. Die Platte hat eine mehrere Meter mächtige zusammenhängende Lößdecke, weshalb ein ziemlich einheitliches Bodenmuster vorzufinden ist (PEMÖLLER, 1969). Als durchschnittliche Höhe des schwach reliefierten Geländes können 150 m angenommen werden. Die langjährigen Mittel (1961 – 1990) für Temperatur- und Niederschläge werden vom Deutschen Wetterdienst (DWD) für nächst der Untersuchungsregion liegende Klimastation Karlsruhe mit 10,3 °C und 770 mm Jahresniederschlag angegeben (DWD, 2003).

3.2.2 Untersuchungsregion Baden-Württemberg (BW)

Die Merkmale dieser Untersuchungsregion sind wesentlich heterogener. Naturräumlich erstreckt sich die Untersuchungsregion von der „Oberen Gäue“ im Westen und Norden bis zur „Mittleren Flächenalb“ im Osten sowie bis zur „Baar“ und dem „Oberen Donautal“ im Süden.

Der Standort Spaichingen liegt am Fuß des westlichen Albtraufs (ca. 650 m ü. N.N.), die Ackerböden sind tiefgründige Lehme des Unteren und Oberen Lias. Die Jahresniederschläge liegen bei > 800 mm. Epfendorf liegt auf der westlichen der Hochflächen (ca. 650 m ü. N.N.), die den Neckar einschließen. Auf den Hochflächen sind dunkle und schwere Lettenkohlenböden vorzufinden. Bezeichnend sind die beachtlichen Jahresniederschläge von > 900 mm. Kennzeichen für den Standort Horb (ca. 530 m ü. N.N.) sind das Mosaik von Lößinseln und lößfreien Lettenkohlenplatten. Die Hauptböden am Standort Haigerloch (ca. 500 m ü. N.N.) sind Lößlehme und schwere Lettenkohlenböden. Der Jahresniederschlag in Haigerloch beträgt 730 mm (HUTTENLOCHER, 1959). Als Besonderheit gilt der Standort Strassberg, das an der Nahtstelle mehrerer Naturräume liegt und aufgrund seiner Höhe (850 m ü. N.N.) einer besonderen Berücksichtigung bedarf. Die Jahresniederschläge für diesen Standort liegen bei über 900 mm. Bestimmt wird dieser Standort von verkarstetem Massenkalk. Dieser Standort wurde aufgrund

dieser außergewöhnlichen Bedingungen in der Klassifikation nicht berücksichtigt. Für das Untersuchungsgebiet BW kann eine durchschnittliche Höhe von 660 m ü. N.N. angenommen werden. Als langjähriges Mittel (1961 - 1990) für die in der Nähe liegende Station Stuttgart/Echterdingen gibt der DWD einen Wert von 8,6 °C an (DWD, 2003).

4 Datenerhebung und Datenverarbeitung

4.1 Fernerkundungsdaten

4.1.1 Hochoflösende Fernerkundungsdaten (LANDSAT TM/ETM+)

Das LANDSAT-Satellitenprogramm wird seit 1972 von der US-Raumfahrtbehörde NASA betrieben. Seither hat es laufend technische Neuerungen gegeben. Die derzeit aktiven Sensoren sind LANDSAT 5 mit dem *Thematic Mapper* (TM) und – seit Mai 2003 mit technischen Schwierigkeiten – LANDSAT 7 mit dem *Enhanced Thematic Mapper* (ETM+). Eine Beschreibung des Satellitenprogramms und –systems ist u. a. bei LILLESAND und KIEFER (1999) und der NASA (2003) zu finden. Die Sensoren verfügen über 7 multispektrale Kanäle im sichtbaren, nahinfraroten bis hin zum thermalen Infrarotbereich, wobei die räumliche Auflösung bei 30 m liegt (TM/ETM+ Thermalkanal 120 m bzw. 60 m Auflösung). Für den Sensor ETM+ steht zusätzlich ein panchromatischer Kanal mit 15 m räumlicher Auflösung zur Verfügung. Die zeitliche Wiederkehrrate beider Sensoren liegt bei 16 Tagen.

LANDSAT TM und ETM+ Daten (siehe Tabelle 2) wurden bereits als georeferenzierte Ausschnitte erhalten, wobei die Daten anhand von 31 - 59 *Ground Control Points* (GCP) auf ATKIS Daten registriert und mit einem RMS-Fehler (ERDAS INC., 1999) im Subpixelbereich georeferenziert wurden. Gegebenenfalls vorhandene Wolken wurden ausmaskiert.

Tabelle 2: Satellitenaufnahmen der Untersuchungsgebiete in Rheinland-Pfalz (RLP) und Baden-Württemberg (BW).

Untersuchungsregion	Datum	Sensor	Path/row
RLP	1.4.01	LANDSAT TM	195/26
	10.5.01	LANDSAT TM	196/26
	6.7.01	LANDSAT TM	195/26
	22.7.01	LANDSAT TM	195/26
	30.7.01	LANDSAT ETM+	195/26
BW	1.4.01	LANDSAT TM	195/26
	12.6.01	LANDSAT ETM+	195/26
	6.7.01	LANDSAT TM	195/26
	22.7.01	LANDSAT TM	195/26
	30.7.01	LANDSAT ETM+	195/26

Der multitemporale Klassifikationsansatz mit der Verwendung von mehreren zeitlich aufeinanderfolgenden Szenen erforderte eine Atmosphärenkorrektur, um eine vergleichbare Datengrundlage zu gewinnen. Alle Aufnahmen wurden mit Hilfe des ATCOR-2- (RLP) bzw. ATCOR-3-Moduls (BW) von ERDAS IMAGINE atmosphärenkorrigiert. Eine ausführliche Beschreibung des Algorithmus ist bei RICHTER (2002) bzw. bei GEOSYSTEMS GMBH (2003)

zu finden. Mit dieser Methodik werden Reflektanzen über Veränderung mehrerer variabler Größen an ein Referenzspektrum angepasst. Messungen mit einem Feldspektrometer erlaubten einen Abgleich von gemessenen zu korrigierten Reflektanzen, der in Abbildung 6 wiedergegeben ist.

Vergleichende Untersuchungen von Satellitenaufnahmen und Feldspektrometermessungen konnten nur an einem bestimmten Termin durchgeführt werden: Für die Satellitenaufnahme (LANDSAT-TM) am 6.7.01 und für die Feldspektrometermessung am 5.7.01. Hier war der zeitliche Abstand von Satellitenaufnahme und Messung mit Feldspektrometer gering genug, um einen Vergleich zuzulassen. Die Messungen konnten für diesen Vergleich innerhalb eines Tages durchgeführt werden. Alle übrigen Messungen erstreckten sich über einen Zeitraum von einer Woche oder mehr. Aufgrund der dynamischen Veränderung des Erscheinungsbildes der Vegetation – insbesondere der Sommergerste ab dem phänologischen Stadium des Schossens – kann dies zu deutlich verändertem spektralen Verhalten führen.

Für die Umrechnung der Reflektanzen des hier verwendeten *Fieldspec* (vergl. Kapitel 4.2.7) zu LANDSAT-Äquivalenten ist zu beachten, dass die Äquivalente nicht über Filterkurven gewichtet, sondern ungewichtet gemittelt wurden. Ungewichtete und gewichtete Spektren können zu leichten Differenzen im NDVI führen, da die Transmission der einzelnen LANDSAT-Kanäle nicht über den gesamten Bandbereich uniform verläuft (JENSEN, 1996). Untersuchungen an den vorliegenden Daten haben jedoch gezeigt, dass die Unterschiede von gewichteten zu nicht gewichteten NDVI im Mittel je Schlag bei nur 0,019 NDVI-Einheiten lagen, was dafür sprach, einer ungewichteten simplifizierten Lösung den Vorrang zu geben. Für Analysen, die eine hohe Präzision erfordern, ist die Vorgangsweise mit Gewichtung zu empfehlen.




Abbildung 6: Reflektanzen eines konkreten Schlages (Epfendorf) von Sommergerste der LANDSAT-TM-Kanäle 1 - 4. LANDSAT-TM-Aufnahme vom 06.07.01 jeweils atmosphärenkorrigiert mit Modell COST bzw. ATCOR sowie nicht atmosphärenkorrigiert im Vergleich zum Feldspektrometer (*Fieldspec VNIR*). Die durchgeführte Atmosphärenkorrektur mit dem ATCOR-Modell zeigt die geringsten Abweichungen zu den Messungen des Feldspektrometers.

Tabelle 3: Minimale und maximale Abweichungen der Reflektanzen von gemessenen Reflektanzen mit Feldspektrometer am Beispiel des Schlages in Epfendorf.

	TM 06.07.01 ohne Atmosphärenkorrektur	TM 06.07.01 COST-Atmosphärenkorrektur	TM 06.07.01 ATCOR Atmosphärenkorrektur
	Abweichung %-Punkte Reflektanz von Feldspektrometer		
Min. Abw.	2,2	2,1	0,1
Max. Abw.	7,2	2,7	0,5

Als Beispiel wurde für einen untersuchten Schlag (Epfendorf) der vorhandene Ausschnitt der LANDSAT-TM-Aufnahme vom 6.7.01 kalibriert (Referenz: GEOSYSTEMS GMBH, 2003) und in Reflektanz umgerechnet, wobei keine Atmosphärenkorrektur erfolgte. Im Vergleich dazu wurde mit dem COST-Modell (CHAVEZ, 1996) atmosphärenkorrigiert. Diese relativ einfache

Atmosphärenkorrektur berücksichtigt eine einheitliche Korrektur für vorhandenen Dunst im jeweiligen Spektralband. Die COST-Korrektur ergab eine klare Verbesserung gegenüber der unkorrigierten Aufnahme, vor allem im blauen Spektralbereich (siehe Abbildung 6), der besonders empfindlich auf Dunst reagiert (LILLESAND & KIEFER, 1999). Die verbleibende Differenz dürfte darauf zurückzuführen sein, dass die Korrektur nur mit einem Ausschnitt erfolgen konnte und dadurch nicht die ausreichende Bildgröße für das Auffinden des dunkelsten Pixels (sogenanntes *dark object*) – üblicherweise einer Vollszene - vorhanden war.

Eine deutlich bessere Anpassung an das mit dem Feldspektrometer gemessene Spektrum ergab die durchgeführte Atmosphärenkorrektur mit dem Atmosphärenkorrekturmodul ATCOR von ERDAS IMAGINE (Abbildung 6). Die Abweichung der beiden Spektren beträgt maximal 0,5 %-Punkte (Tabelle 3). Angesichts der unterschiedlichen Aufnahmezeitpunkte und der unterschiedlichen Aufnahmegeometrien (*Fieldspec* vs. LANDSAT) kann diese Übereinstimmung als sehr zufriedenstellend betrachtet werden. Die gute Übereinstimmung kann zudem als Qualitätskriterium der durchgeführten Atmosphärenkorrektur gewertet werden. Im weiteren Verlauf der Untersuchungen wurden sämtliche LANDSAT-TM-Szenen mittels ATCOR korrigiert.

Der Vergleich zeigt, dass Referenzspektren, die mit dem Feldspektrometer gewonnen werden, zur Atmosphärenkorrektur geeignet wären. Das Problem besteht jedoch darin, sowohl Spektren eines bodennahen Radiometers als auch von Satellitenszenen mit einer ausreichend hohen zeitlichen Auflösung zur Verfügung zu haben. Dazu müsste für jeden typischen Beobachtungsstandort eine spektrale Bibliothek angelegt werden, wobei angesichts der rasanten phänologischen Entwicklung der Braugerste der Abstand der Messungen nur wenige Tage betragen dürfte. Deshalb wurde im vorliegenden Fall auf gemittelte Referenzspektren des Atmosphärenkorrekturmoduls ATCOR zurückgegriffen. Die dabei verwendeten Referenzspektren (z. B. Wasser und Nadelwald) unterliegen weitaus geringeren zeitlichen Schwankungen als dies für Braugerste der Fall ist.




Abbildung 7: Variationskoeffizient der Rückstreuung pseudoinvarianter Objekte (Industriedächer) für eine Zeitreihe von 5 Satellitenaufnahmen aus dem Jahr 2001 (Untersuchungsregion Rheinland-Pfalz), dargestellt für 4 LANDSAT-TM-Kanäle – mit und ohne Atmosphärenkorrektur (ATCOR).

Da der Vergleich von fernerkundlich abgeleiteten und bodennah gemessenen Reflektanzen nur bei einer Aufnahme (6.7.01) anwendbar war, wurde, gewissermaßen als zweite Qualitätskontrolle, die zeitliche Varianz der LANDSAT-Aufnahmen untersucht. Dabei wurde die Auswirkung der Atmosphärenkorrektur auf ein sogenanntes „*pseudoinvariant feature*“, ein über den Jahresverlauf im spektralen Sinne quasi gleichbleibendes Objekt überprüft. Idealerweise würden die pseudoinvarianten Ziele über den gesamten Jahresverlauf nahezu gleich bleiben. Im vorliegenden Fall wurden Industriedächer als Testflächen herangezogen.

Über eine Zeitreihe von 5 Satellitenaufnahmen wurden die Variationskoeffizienten dieser Objekte anhand der ersten 4 LANDSAT-TM-Kanäle für atmosphärenkorrigierte und unkorrigierte Aufnahmen berechnet und als Variationskoeffizient ausgedrückt. Wie in Abbildung 7 ersichtlich, ist die Streuung der atmosphärenkorrigierten Aufnahmen deutlich geringer als in unkorrigierten Aufnahmen. Im Durchschnitt streuen die atmosphärenkorrigierten Aufnahmen um ein Drittel weniger. Der Vergleich wurde auf die ersten vier LANDSAT-TM-Kanäle beschränkt, zumal die Kanäle 5 und 7 am stärksten wasserempfindlich sind und Kanal 6 (thermisch) für einen derartigen Vergleich nicht geeignet ist.

4.1.2 Grobauflösende FE-Daten (NOAA-AVHRR NDVI MVC)

Ursprünglich für Anwendungszwecke in der Meteorologie und Ozeanographie geplant und seit 1979 in Betrieb, hatte sich das nach der US-Behörde NOAA (*National Oceanic and Atmospheric Administration*) benannte Satellitenprogramm alsbald auch für terrestrische Applikationen als geeignet herausgestellt. Der AVHRR-Sensor auf den NOAA-Satelliten verfügt über spektrale

Bänder im sichtbaren und infraroten Bereich (LILLESAND & KIEFER, 1999), die räumliche Auflösung der LAC-Daten (*local area coverage*) liegt bei 1,1 km.


Als Grundlage für das Ertragsprognosemodell wurden NOAA-AVHRR-NDVI-Maximalwertkompositen verwendet. Diese Daten werden vom DFD/DLR bereitgestellt und sind über Internettechnologie frei erhältlich. Die vorhandenen Daten lagen als NDVI-Wochenkompositen für die Jahre 1995 - 2002 vor.

Die bereitgestellten Daten sind nicht atmosphärenkorrigiert. Neben der Atmosphäre spielt außerdem die Aufnahmegeometrie eine wichtige Rolle: Dazu zählt sowohl die Beobachtungsgeometrie (Sensor) als auch die Beleuchtungsgeometrie (Sonnenstand) in Bezug zum untersuchten Objekt sowie deren räumliche Anordnung zueinander. Die Beleuchtungsverhältnisse in Abhängigkeit beider Geometrien sowie in Abhängigkeit der Wellenlänge werden mathematisch mit der bidirektionalen Verteilungsfunktion (BRDF - *Bidirectional Reflectance Distribution Function*) beschrieben (SCHOTT, 1997).


Teilweise können diese Fehler über die Bildung von Quotienten (NDVI) und über die Bildung von Maximalwertkompositen kompensiert werden (HOLBEN, 1986). Versuche einer empirischen Atmosphären- und BRDF-Korrektur wie bei (COLEMAN, 1995) erbrachten nicht den gewünschten Effekt. Die entsprechenden Korrekturen dürften demnach für Kompositen nicht durchführbar sein. Alternativ bietet sich die Möglichkeit einer Glättung von NDVI Zeitserien an, allerdings mit dem Nachteil, gegebenenfalls Daten zu verfälschen.

Bei einer Sichtkontrolle der Aufnahmen wurde festgestellt, dass trotz der Maximalwertbildung in einigen Aufnahmen erhebliche Anteile an Wolkenbedeckung sichtbar waren, welche sich störend auf die weitere Prozessierung auswirkten. Um dies zu umgehen, wurden aus den vorhandenen Wochenkompositen durch Maximierung (Verwendung des größeren der 2 aufeinanderfolgenden Wochenwerte) 2-Wochen-Kompositen generiert, wodurch die Wolkenbedeckung auf ein erträgliches Restmaß reduziert werden konnte (siehe das Beispiel in Abbildung 8).


Die Projektionsparameter der originalen und reprojizierten AVHRR-NDVI-Szenen sind im Anhang der Tabelle A 2, Tabelle A 3 und Tabelle A 4 entnehmbar.




21.5. - 3.6.2002



7.5. - 20.5.2002





23.4. - 6.5.2002




9.4. - 22.4.2002




25.3. - 8.4.2002




16.7. - 29.7.2002



2.7. - 15.7.2002



18.6. - 1.7.2002



4.6. - 17.6.2002

Abbildung 8: Zeitreihe von 2-wöchigen NOAA-AVHRR-NDVI-Maximalwertkompositen 2002.

4.2 Bodengestützte Daten

4.2.1 Meteorologische Daten

Für beide Untersuchungsgebiete wurden für die Jahre 1995 bis 2002 folgende Daten vom Deutschen Wetterdienst (DWD) verwendet:

- Mittlere tägliche Lufttemperatur
- tägliche potentielle Evapotranspiration (ET_p), berechnet nach HAUDE (1955)
- tägliche aktuelle (tatsächliche) Evapotranspiration (ET_a), berechnet nach einer modifizierten Methode nach HAUDE (DVWK, 1984).

Die Daten wurden von 14 repräsentativen Klimastationen in der Untersuchungsregion BW und für 4 Klimastationen in der Untersuchungsregion RLP übernommen. Die Verortung der Klimastationen erfolgte in einem GIS (siehe Abbildung 4 und 5).

4.2.2 Phänologische und naturräumliche Daten

Die Phänologie der Sommergerste wurde vom DWD nur bis 1990 berichtet. Von 1981 bis 1990 standen die Beobachtungstermine folgender phänologischer Stadien zur Verfügung:

- Beginn der Aussaat (AS)
- Beginn des Auflaufens (AL)
- Beginn des Schossens (SCH)
- Beginn des Ährenschiebens (ÄS)
- Beginn der Gelbreife (GR)

Die naturräumlichen Einheiten konnten aus Kartenmaterial der Literatur (HUTTENLOCHER, 1959; PEMÖLLER, 1969) extrahiert werden. Die entsprechenden Karten wurden digitalisiert, georeferenziert und in das GIS übernommen.

4.2.3 CORINE land cover

Die Europäische Umweltagentur (*European Environment Agency*) stellt mit *CORINE land cover* eine europaweite Karte bereit, welche die Landbedeckung in 44 Klassen einteilt und in einer Rasterweite von 250 m wiedergibt (EEA, 2003). Es wurde die Version 12/2000 verwendet. Von besonderem Interesse ist die Klasse „*non irrigated arable land*“.

4.2.4 Pedologische Daten

Es wurden verschiedene Bodenkarten der Untersuchungsgebiete verwendet. Während in BW eine digitale Version einer regionalen Bodenübersichtskarte (BÜK200) zur Verfügung stand, musste in RLP auf analoge Quellen zurückgegriffen werden (Übersichtskarte der Bodentypen-Gesellschaften von Rheinland-Pfalz). Die analogen Daten wurden digitalisiert, georeferenziert und in das GIS integriert. In einem weiteren Schritt mussten die aus unterschiedlichen Quellen stammenden Bodeninformationen vereinheitlicht werden.

4.2.5 Topographische Daten und Flurstücksdaten

Es wurden topographische Karten (TK) der Untersuchungsgebiete in verschiedenen Maßstäben (1 : 25 000 bis 1 : 200 000) in teils analoger, teils digitaler Form erworben. Von den örtlichen Vermessungs- und Katasterämtern bzw. den Landesvermessungsämtern wurden Grundrissdaten der untersuchten Trainingsgebiete angefordert. Die Daten stammten aus mehreren Quellen (ALK, DGK5, u. a.) und bildeten u. a. Flurstücke, Gebäude, Straßenflächen, Gewässerflächen, etc. ab. Diese Daten mussten in verschiedenen Formaten (EDBS, DXF, Rasterformat) bzw. verschiedenen Maßstäben erworben werden, teils georeferenziert und digitalisiert sowie in das GIS integriert werden.

Es ergaben sich Schwierigkeiten, die kartierten Schläge den Grundstückseinheiten der Flurkarten zuzuordnen, sodass zusätzlich Luftbilder vergangener Jahre besorgt wurden. Dies war erforderlich, weil bei den Feldkartierungen kein GPS zur Verfügung stand. Damit sollte die Zuordnung von Nutzungsgrenzen zu Eigentumsgrenzen erleichtert werden, die vor allem in den Gebieten mit Realteilungsrecht (RLP) divergierten. Die Luftbilder wurden mosaikiert, georeferenziert und in das GIS eingebunden.

Für das stärker reliefierte Untersuchungsgebiet in BW wurde ein digitales Höhenmodell (horizontale Auflösung 200 m) angeschafft, in RLP wurde darauf verzichtet. Es handelt sich dabei um ein DHM mit einer horizontalen Auflösung von 200 m.

4.2.6 Felddaten und Kartierung

Für die Klassifizierung von Sommergerste wurden Felderhebungen nach dem Flächenstichprobenverfahren durchgeführt (BARBOSA et al., 1996; MEINEL & HENNERSDORF, 2002). In beiden Untersuchungsregionen wurden im Umkreis der näher untersuchten Braugersteflächen zusätzliche Fruchtarten kartiert. Insgesamt wurden 2001 in RLP 621 ha und in BW 449 ha kartiert.

4.2.7 Feldspektrometermessungen

Die Messungen erfolgten mit dem Feldspektrometer *Field Spec VNIR* der Fa. *Analytical Spectral Devices* an 5 Messstellen pro Testfeld und an Tagen mit wenig wechselnden Lichtverhältnissen. Die technischen Spezifikationen des Gerätes sind dem Anhang (Tabelle A 1) zu entnehmen. Die Messung erfolgte analog zu MÜLLER (2000). Dabei wird ein Referenzspektrum ermittelt, indem die Reflexion einer Fläche gemessen wird, die zu 100 % reflektiert („idealisiertes Weiß“). Durch diese Kalibrierung können die nachfolgend gemessenen Spektren in relative Reflexionswerte konvertiert werden. An jeder Messstelle wurde in dreifacher Wiederholung in Höhen von 60 und 200 cm über der Bestandesoberfläche gemessen. Zur Standardisierung der Messungen wurde die „Messpistole“ des Feldspektrometers auf einem Stativ befestigt und in Nadir-Position ausgerichtet. Die Feldmessungen erfolgten zwischen 11.00 - 15.00 Uhr, um den Einfluss des Sonnenstands und der atmosphärischen Störgrößen zu minimieren (EGBERT & ULABY, 1972). Die Messungen eines jeweiligen Schlages wurden gemittelt.

4.2.8 Agrarstatistische Daten

Über die Landesstatistikämter wurden die Flächenerträge für Sommergerste (dt ha⁻¹) der Jahre 1995 - 2002 auf Kreisebene bezogen. Hinzugezogen wurden Daten, welche Aussagen über die vorwiegende Landnutzung und die landwirtschaftliche Nutzung zuließen.

4.2.9 Administrative Daten

Diese Daten umfassen Gemeinde- und Kreisgrenzen der Untersuchungsgebiete. Es handelt sich dabei um Vektordaten eines Ausschnitts der Verwaltungsgrenzen (Gemeinden) 1 : 250 000 (VG 250) der Bundesrepublik Deutschland. Mit den Grenzen dieser Einheiten wurden zudem die Außengrenzen der untersuchten Regionen festgelegt (Tabelle 4).

Tabelle 4: Flächenausmaß der untersuchten Regionen

Untersuchungs- region	Landkreis	Landkreis Kennung	Flächenausmaß [km ²]
RLP	Germersheim	Germ	460
	Südliche Weinstrasse	Süw	640
BW	Freudenstadt	Fds	870
	Rottweil	Rott	770
	Tuttlingen	Tutt	734
	Zollern-Alb-Kreis	Zak	917

4.3 Klassifikation

4.3.1 Klassifikationsmethoden

Da sich die Produktion eines Untersuchungsgebietes aus dem Flächenertrag und der Anbaufläche der untersuchten Kultur zusammensetzt, wurden die Untersuchungsgebiete auf Basis von LANDSAT-Aufnahmen klassifiziert. Dabei sollte geprüft werden, in welcher Art und Weise, ob und mit welcher Genauigkeit Sommergerste klassifiziert werden kann. Obwohl in Deutschland überwiegend Sommergerste zur Mälzung verwendet wird, muss berücksichtigt werden, dass von der klassifizierten Sommergerste nur ein Teil als Braugerste geeignet ist, während der Rest überwiegend Futterzwecken dient.

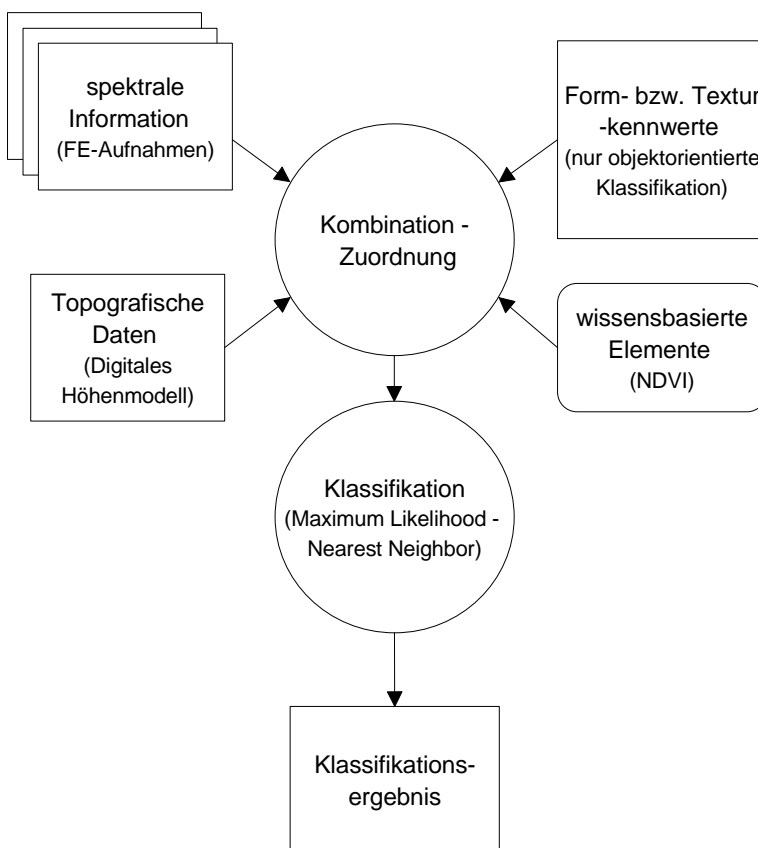


Abbildung 9: Input-Daten der Klassifikation

Als Klassifikationsmethoden der multitemporalen LANDSAT-Aufnahmen wurde ein pixelorientierter und, vergleichend dazu, ein objektorientierter Ansatz gewählt. Der multitemporale Ansatz begründet sich darin, dass die spektrale Information einer FE-Szene kaum für eine Fruchtartenklassifikation ausreicht (JEWELL, 1989). Als Software wurde ERDAS IMAGINE (ERDAS INC., 2001) bzw. ECOGNITION (BAATZ et al., 2001) eingesetzt. In beiden Fällen wurden neben spektralen Merkmalen zusätzliche thematische Informationsschichten und über

Entscheidungsregeln definiertes Expertenwissen verwendet (Abbildung 9). Hierfür konnten in erster Linie Schwellenwerte für den NDVI eingesetzt werden. Diese Werte wurden aus den bekannten Musterflächen abgegriffen und auf die Untersuchungsregion ausgedehnt. Ähnliche Vorgehensweisen werden bei FROST (1986) und COHEN & SHOSHANY (2002) beschrieben.

4.3.1.1 Pixelorientierte Klassifikation

Mit diesem Ansatz erfolgt die Klassifikation für jedes einzelne Pixel. Es werden keine Cluster gleichartiger Pixel gebildet. Dies führt zwar zu einem Klassifikationsergebnis mit einem inhomogenen Charakter, gleichzeitig unterliegt es jedoch keiner Generalisierung.

In einem ersten Schritt wurden Wasserflächen, bewaldete Flächen und versiegelte Flächen auf Basis einer überwachten *Maximum-Likelihood*-Klassifikation (SWAIN & DAVIS, 1978) ausmaskiert, um störende Einflussfaktoren vor der eigentlichen Klassifikation zu reduzieren (verwendete Aufnahme: 22.7.01). Für die verbleibenden potentiellen landwirtschaftlichen Flächen wurden die 4 älteren Aufnahmen nach Fruchtarten klassifiziert. Dafür wurde eine überwachte *Maximum-Likelihood*-Klassifikation durchgeführt, welche die 3 erstgereihten Fruchtarten jedes Pixels, geordnet nach ihrer Eintrittswahrscheinlichkeit, beinhaltete. Damit sollten auch jene Bildpunkte erhalten bleiben, die Sommergerste erst als 2. oder 3. Frucht in ihrer Eintrittswahrscheinlichkeit ausweisen. Die weitere Verrechnung sollte anhand wissensbasierter Regeln die „wahre“ Sommergerste auf ihr tatsächliches Maß eindämmen. Mit dieser Technik konnten im weitesten Sinne *Fuzzy*-Techniken in eine *Maximum-Likelihood*-Klassifikation integriert werden. Bei *Fuzzy*-Klassifikationen erfolgt die Zuweisung eines Pixels zu einer Klasse anhand einer Zugehörigkeitsfunktion; dem Bildpunkt wird die wahrscheinlichste Klasse zugewiesen. *Fuzzy*-Klassifikationen haben keine starren Klassengrenzen, jedes Pixel kann mehreren verschiedenen Klassen angehören (JENSEN, 1996).

Die Einzelbilder wurden nun zusammengeführt, wobei jene Bildpunkte je Aufnahme weiterhin berücksichtigt wurden, welche die Sommergerste als 1., 2., oder 3. Frucht in ihrer Eintrittswahrscheinlichkeit auswiesen (*Bool'sche* ODER Verknüpfung). Die darauf folgende Verknüpfung zwischen den Bildern erfolgte mit einer *Bool'schen* UND Verknüpfung, sodass die Ausweisung als Sommergerste in allen 4 Aufnahmen gegeben sein musste. Ebenso mit einer zwingenden UND Verknüpfung erfolgte auf dieser Ebene die Anknüpfung an den wissensbasierten Teil des Klassifikationsmodells. In diesem Teil wurden mehrere Bedingungen über den NDVI festgelegt (Tabelle 5): Demnach durfte Sommergerste in der frühesten Aufnahme (1.4.01) keine Vegetationsdecke aufweisen. In den letzten beiden Aufnahmen (22.7. und 30.7.01) wurde ein Schwellenwert festgelegt, der sicherstellte, dass keine grüne Vegetation erfasst wurde. Mit diesen Maßnahmen sollten sukzessive „konkurrierende“ Früchte aus dem Klassifikationsmodell ausgeschlossen werden (z. B. Wintergetreide, Mais und Kartoffel). Hafer wurde über einen zusätzlichen Schwellenwert ausgeschlossen. Für Hafer wurde eine weniger rasche Abreife als für Sommergerste beobachtet, sodass die Veränderung des NDVI von einer Aufnahme zur nächsten dafür als Kriterium herangezogen werden konnte. Der Klassifikationsalgorithmus wurde für 2 Höhenstufen mit der Höhengrenze bei 600 m definiert. Die jeweiligen Ergebnisse wurden zusammengeführt. Um ein sehr starkes Auftreten einzelner und nicht im Verbund vorliegender Pixel oder Lücken (*salt-and-pepper-effect*) zu unterdrücken, wurden Filter eingesetzt. Da die

Methodik auf Ausschließlichkeit beruht, liegt als Resultat eine binäre Bilddatei vor, die Sommergerste und Restflächen ausweist.

Tabelle 5: Wissensbasierte Regeln und Schwellenwerte der pixelbasierten Klassifikation

Regel	Unter 600 m Höhenlage	Über 600 m Höhenlage
Identifikation der „Sommerungen“	NDVI 1.4.01: < 0,3	NDVI 1.4.01: < 0,3
Nicht grüne Vegetation	NDVI 30.7.01: > 0,3; < 0,57; NDVI 22.7.01: < 0,77	NDVI 30.7.01: > 0,3; < 0,65; NDVI 22.7.01: < 0,77
Nicht Hafer	Differenz NDVI 22.7.01 – 6.7.01: < -0,1	Differenz NDVI 22.7.01 – 6.7.01: < -0,1
Höhenlage	DHM: ≤ 600 m	DHM: > 600 m

4.3.1.2 Objektorientierte Klassifikation

Mit objektorientierter Klassifikation wird der Ansatz verfolgt, zunächst über den Zwischenschritt der Segmentierung über definierte Kriterien *Cluster* gleichartiger Merkmalsausprägung zu bilden, die in der Folge als Objekte in der Klassifikation einer einheitlichen Behandlung unterliegen (BAATZ et al., 2001; BAATZ & SCHÄPE, 2000).

Die Skala, auf der die Segmentierung vorgenommen werden soll, lässt sich über den Skalierungsparameter bzw. *scale parameter* anpassen. Dies ist ein abstrakter Term, der die maximal erlaubte Heterogenität eines resultierenden Objektes bestimmt. Er ist damit indirekt ausschlaggebend für die Größe der zu bildenden Segmente, gleichzeitig sind die Ergebnisse der Segmentierung aber nur in Kombination mit einer gegebenen Pixelgröße (da unterschiedlicher Heterogenitätsgrad) nachvollziehbar. Im vorliegenden Fall (LANDSAT – Pixelgröße 30 m) wurde die Segmentierung mit dem Skalierungsparameter 2 vorgenommen, da dadurch die kleinen Schläge als einzelnes Segment noch erfasst wurden, während die größeren Schläge aus mehreren Segmenten bestanden.

Die Segmentierung kann neben dem Skalierungsparameter durch die Festlegung und Gewichtung von spektralen und/oder räumlichen Homogenitätskriterien der resultierenden Objekte beeinflusst werden (NIEMEYER, 2001). Dabei handelt es sich um Kriterien zur Festlegung von Farbhomogenität und Formhomogenität. Die Farbhomogenität wird über die Summe der Standardabweichungen der Spektralwerte der Objektpixel über alle Kanäle definiert, die Formhomogenität erklärt sich aus der relativen Abweichung der Kantenlänge von der kompaktesten Form (Kreis). Die zu definierenden Gewichtungsfaktoren wurden mit 0,9 für Farbe/*color* (entspricht den spektralen Merkmalen) und 0,1 für Form/*shape* gewählt; entsprechend lag der Schwerpunkt der Kriterien für die Segmentierung mit 90 % bei den spektralen Merkmalen. Die Form-Eigenschaften ihrerseits werden nochmals in die Kriterien Glättung/*smoothness* bzw. Kompaktheit/*compactness* unterteilt, hierfür wurde eine Gewichtung von 0,9 bzw. 0,1 gewählt.

Dabei handelt es sich bei *smoothness* um ein Kantenkriterium und bei *compactness* um ein Flächenkriterium: Das Kantenkriterium *smoothness* S ist definiert als das Verhältnis zwischen der Objektkantenlänge l und der kürzesten Kantelänge b , die durch eine *Bounding Box* um das Bildobjekt gegeben ist (Gleichung [7]). Die *Bounding Box* ist der kleinste rechteckige Kasten um ein Objekt, der es vollständig enthält. Das Flächenkriterium *compactness* C lässt sich als Beziehung zwischen der aktuellen Kantenlänge l und der Objektfläche n in Pixel ermitteln (Gleichung [8]).

$$S = \frac{l}{b} \quad [7]$$

$$C = \frac{l}{\sqrt{n}} \quad [8]$$

Das Flächenkriterium C erzeugt vorzugsweise Objekte, die sehr kompakt, d. h. der Kreisform angenähert sind. Beim Kantenkriterium S werden dagegen auch längliche Objekte zugelassen, die eine relativ glatte Kante haben (MITTELBERG, 2001). Da die Schläge der Untersuchungsregion häufig auch länglich ausgebildet waren, wurde das Kantenkriterium *smoothness* - S deutlich höher gewichtet.

Als Eingangsdaten in die Segmentierung wurde der rote und der infrarote Kanal (3 und 4) jeweils mit dem Faktor 2 gewichtet, alle restlichen Kanäle mit dem Faktor 1. Der blaue Kanal (1) wurde für die Segmentierung generell nicht verwendet.




Abbildung 10: Beispiel einer Zugehörigkeitsfunktion mit „scharfer“ Begrenzung. Das Objekt wird nur dann als Sommergerste klassifiziert, wenn der NDVI zwischen 0,15 und 0,3 liegt.

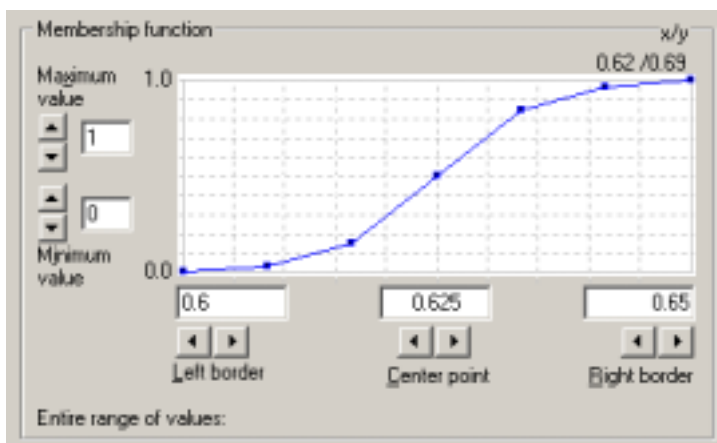


Abbildung 11: Beispiel einer Zugehörigkeitsfunktion für die Klasse „Zuckerrübe“. Das Objekt wird bei einem NDVI < 0,6 nicht, bei einem NDVI > 0,65 als Zuckerrübe klassifiziert. Der Unschärfbereich liegt zwischen NDVI 0,6 und 0,65 (0,6...0,65) und verläuft über eine sigmoide Kurve. In diesem Bereich kann das Objekt als Zuckerrübe klassifiziert werden, wenn die Zugehörigkeitswahrscheinlichkeit zur Zuckerrübe höher ist als zu Konkurrenzklassen.

sigmoiden Kurve. Eine Vorklassifikation zur Ausmaskierung wurde hier nicht durchgeführt, zumal anzunehmen war, dass durch die vorgeschobene Segmentierung (und dadurch Generalisierung) die Konfusion deutlich abnimmt. Vom objektorientierten Ansatz wurde erwartet, dass das Problem des *salt-and-pepper*-Effektes deutlich reduziert wird.

In der multitemporalen Klassifikation wurde der *Nearest-Neighbor*-Algorithmus, welcher zudem Möglichkeiten einer unscharfen (*fuzzy*) Abgrenzung von Merkmalsräumen in der Klassifikation vorsieht, auf die Kanäle aller 5 vorhandenen Aufnahmen angewandt (BAATZ et al., 2001). Das heißt, dass Objekte gegebenenfalls auch dann einer bestimmten Klasse zugewiesen werden können, wenn deren

Zugehörigkeitswahrscheinlichkeit nicht bei 1, aber zwischen 0 und 1 liegt. Die Zuweisung eines Objektes hängt somit von der Zugehörigkeitswahrscheinlichkeit ab, die über Zugehörigkeitsfunktionen definiert werden kann. Analog zur pixelbasierten Klassifikation kamen neben spektralen Merkmalsräumen wissensbasierte Regeln hinzu, die über Schwellenwerte des NDVI und teilweise über Formparameter (RUSS, 1995) definiert wurden (Tabelle 6). Bei der Verwendung von Schwellenwertbereichen wurde teils auf scharfe Begrenzungen, teils auf unscharfe Begrenzungen zurückgegriffen (siehe Abbildung 10 und Abbildung 11). Im letzteren Fall folgt die Zugehörigkeitsfunktion im Unschärfbereich in der Regel einer

Als Klassifikations-Trainingsflächen der Klasse „Sommergerste“ dienten die näher untersuchten Braugerstenschläge, für alle übrigen Klassen zufällig ausgewählte und kartierte Flächen im näheren Umkreis. Für die Evaluierung wurde ein Teil der *Ground-Truth*-Erhebungen zurückgehalten, der für eine unabhängige Prüfung der Klassifikation eingesetzt wurde.

Aufgrund der geringen Anzahl an Trainings-Objekten, die nach der Segmentierung verblieben, wurde bei der objekt-orientierten Klassifikation auf die Trennung in Höhenklassen verzichtet. Im Gegensatz zur pixelorientierten Klassifikation mit dem Ansatz der Ausschließlichkeit, wurden bei der objektorientierten Klassifikation die landwirtschaftlichen Hauptkulturen (einschließlich Sommergerste) sowie die Landbedeckungsklassen „Wasserflächen“, „Wald“ und „Versiegelung“ auf derselben Ebene klassifiziert. Die landwirtschaftlichen Hauptkulturen unterschieden sich nach der jeweiligen Region und richteten sich nach deren Vorkommen in den vorgenommenen Kartierungen. Neben der Sommergerste wurden in RLP 9 weitere und in BW 6 weitere Hauptkulturen erfasst (siehe Anhang: Tabelle A 7 und Tabelle A 8).

Tabelle 6: Wissensbasierte Regeln und Schwellenwerte der objektorientierten Klassifikation, Untersuchungsregion RLP und BW. Schwellenwertbereiche mit unscharfer Grenze sind mit Punkten gekennzeichnet (z. B. 0,2...0,3), jene mit scharfer Grenze mit Bindestrich (z. B. 0,04 - 0,20).

Klasse	Untersuchungsregion RLP		Untersuchungsregion BW	
	Aufnahme- datum	NDVI Schwellenwerte	Aufnahme datum	NDVI Schwellenwerte
Sommergerste	1.4.01	0,04 – 0,20	1.4.01	0,04 – 0,25
	10.5.01	0,19 – 0,90	12.6.01	0,69 – 0,91
	6.7.01	0,30 – 0,66	6.7.01	0,50 – 0,85
	22.7.01	0,14 – 0,33	22.7.01	0,35 – 0,79
	30.7.01	0,15 – 0,30	30.7.01	0,33 – 0,65
Winterweizen	1.4.01	> 0,15...0,50	1.4.01	> 0,28...0,37
Wein	22.7.01	> 0,55...0,60		-
Raps	1.4.01	> 0,10...0,40	1.4.01	> 0,30...0,33
Mais	6.7.01	> 0,60...0,70		-
Kartoffel	6.7.01	> 0,48...0,55		-
	22.7.01	> 0,50...0,55		-
Zuckerrübe	6.7.01	> 0,60...0,65		-
	22.7.01	> 0,60...0,65		-
Winterroggen	1.4.01	> 0,15...0,50		-
Tabak	6.7.01	> 0,30...0,55		-
	22.7.01	> 0,60...0,80		-
Mais		-	1.4.01	< 0,35...0,4
			6.7.01	< 0,65...0,75
Hafer		-	6.7.01	< 0,70...0,72
			NDVI- Differenz 6.7.01– 22.7.01	< 0...0,14
Wintergerste		-	1.4.01	> 0,15...0,50
Grünland		-	6.7.01	> 0,60...0,65
			22.7.01	> 0,60...0,65
			30.7.01	> 0,60...0,65
Laubwald		-		-
Nadelwald		-		-
Versiegelung 1 ¹	1.4.01	< 0,45...0,50	1.4.01	< 0,45...0,50
	10.5.01	< 0,45...0,50	12.6.01	< 0,45...0,50
	6.7.01	< 0,45...0,50	6.7.01	< 0,45...0,50
	22.7.01	< 0,45...0,50	22.7.01	< 0,45...0,50
	30.7.01	< 0,45...0,50	30.7.01	< 0,45...0,50
Versiegelung 2 ^{1,2}	10.5.01	< 0,20...0,25	12.6.01	< 0,60...0,70
Wasser		-		-

¹) Die Klassen „Versiegelung“ beinhalten auch offene Ackerflächen

²) Das Längen-Breiten-Verhältnis wurde für Versiegelung 2 (Verkehrswege) mit > 1...1,5 festgelegt

4.4 Ertragsprognosemodell

Vereinfacht beschrieben, werden bei den auf empirisch-statistischer Basis entwickelten Prognosemodellen historische Zeitreihen berichteter Ernteerträge (auf Landkreisebene) mit historischen Fernerkundungsdaten, die einer bestimmten Prozessierung und Auswahl unterliegen, verglichen. Dabei auftretende Korrelationen, die häufig nur über bestimmte Zeiträume signifikant sind, werden genutzt, um in einem zu prognostizierenden Jahr anhand von Fernerkundungsdaten den Ernteertrag vorherzusagen. Mit NOAA-AVHRR-NDVI-Maximalwertkompositen standen sowohl eine ausreichend lange kontinuierliche historische Datenreihe als auch Daten des aktuellen Erhebungszeitraums zur Verfügung.

Bei der räumlichen Auflösung von 1,1 km (Nadir) können in Südwestdeutschland keine Einzelschläge beobachtet werden. Vielmehr wird der Gesamtzustand der beobachteten Vegetation erfasst, der aus einer Vielzahl von Kulturen bestehen kann. Mittels *CORINE land cover*, einer europäischen Karte der Landbedeckung, kann die Beobachtung auf das Ackerland eingeschränkt werden. In *CORINE* entspricht dies der Klasse „*non-irrigated arable land*“. Trotzdem verbleibt auf Ackerland eine Vielzahl an möglichen Kulturen. Für die Anwendung dieses Modells ist deshalb notwendig, dass die Mehrzahl der Hauptkulturen dem Getreide zugeordnet werden kann (siehe Abbildung 12 a – b). Da Getreidekulturen ab den Langtagverhältnissen ähnliche phänologische Eigenschaften zeigen, können aus den NOAA-AVHRR-Daten indirekte bzw. analoge Aussagen zur Sommergersteentwicklung abgeleitet werden. Die Literatur beschreibt diese Methode in verschiedenen Varianten (siehe 2.3.1). Obwohl die Mischinformation auch durch die Verwendung von Ackermasken nicht gänzlich eliminiert werden kann, kann dadurch das erhaltene Signal verstärkt werden, zumal die Bodenbedeckungen, die über das Jahr relativ konstant bleiben, nicht zur Abschwächung des NDVI beitragen. Das bedeutet, dass durch die Beschränkung der Anwendung auf die Landbedeckungskategorie „Ackerflächen“ unter Verwendung von *CORINE* ein deutlicheres NDVI-Signal während des Beobachtungszeitraumes erhalten wird, als dies der Fall wäre, wenn man keine Differenzierung in Landbedeckungskategorien vornähme.




Abbildung 12 a - b: Anteile der Getreidekulturen am Ackerland in den Untersuchungsregionen, der Bodennutzungshaupterhebung 1999 der Statistischen Landesämter RLP (a) und BW (b) entnommen.

Das Modell berücksichtigt die Eingabedaten, die von Kulturmaßnahmen (z. B. Düngung, Bewässerung, Saatedichte, etc.) oder der Sortenwahl herrühren, nicht direkt. Diese Faktoren werden, soweit sie sich abbilden, indirekt optisch erfasst. Große Unterschiede sind hier nicht zu erwarten, da die Landwirte der Untersuchungsregionen in der Regel ausgebildet und erfahren sind bzw. Beratung in Anspruch nehmen und nach den Regeln der „guten fachlichen Praxis“ arbeiten, womit eine relativ homogene Bewirtschaftungspraxis vorausgesetzt werden kann. Effekte von Sortenunterschieden der Sommergerste dürften in den untersuchten Regionen kaum auftreten, zumal bei Felderhebungen festgestellt wurde, dass der Großteil der Untersuchungsflächen (ca. 90 %) einer Sorte (*Scarlett*) zugerechnet werden konnte. In wenigen Fällen kam auch die Sorte *Pasadena* vor. Die Aufwandmengen von Stickstoff im Untersuchungsgebiet bewegten sich zwischen 70 und 110 kg N ha⁻¹. Häufigste Vorfrucht war Winterweizen. Pflanzenschutzmaßnahmen (Herbizid- und Fungizideinsatz) wurden im Untersuchungsgebiet durchwegs durchgeführt. Die Bestände waren auch in der Reifephase nicht übermäßig verunkrautet und vom phytomedizinischen Standpunkt unauffällig. Dies spricht für ein relativ einheitlich betriebenes Pflanzenschutzmanagement, soweit es die Wirkung der Maßnahmen betrifft.

Die berichteten Ernteerträge wurden bewusst nicht trendkorrigiert, da sich der technische Fortschritt (z. B. raschere Blattmassebildung) zum Teil auch in den historischen Aufnahmen abzeichnet. Eine erfolgte Trendkorrektur hätte somit eine einseitige Datenveränderung bedeutet. Es muss aber auch kritisch angemerkt werden, dass sich andere Aspekte des technischen Fortschritts nicht im abbildenden System erfassen lassen (z. B. höhere Kornzahl/Ähre). Die Notwendigkeit einer

Trendkorrektur ist somit strittig. Da es sich jedoch um einen rechnerischen Näherungsvorgang mit entsprechender Generalisierung und Fehleranfälligkeit handelt, wurde hierauf verzichtet.

Wegen der gebietsspezifischen Besonderheiten wurden die Berechnungen für die 2 Untersuchungsgebiete auf Landkreisebene bzw. auf regionaler Ebene durchgeführt. Eine Übertragung der Modelle auf andere Regionen ist nicht uneingeschränkt und nur durch entsprechende Änderungen möglich. Bei großräumiger Anwendung empfiehlt sich eine Regionalisierung über Naturräume.

Der Vorteil der zeitlich hohen Auflösung von NOAA-AVHRR-Daten wird durch die Bildung von Maximalwertkompositen teilweise wiederum geschmälert. Die Bildung von Mehrtageskompositen ist jedoch eine praktische Methode, um dem Problem der Wolkenbedeckung zu begegnen. Im konkreten Fall hat sich nach einer visuellen Prüfung gezeigt, dass die ursprünglichen Wochenkompositen besser zu 2-Wochenkompositen transformiert werden, um den Einfluss der Wolkenbedeckung zu reduzieren. Die Wahl der Periode zur Bildung von Mehr-Tages-Kompositen gleicht einer Gratwanderung; einerseits soll die Wolkenbedeckung eliminiert werden, andererseits soll so wenig Information wie möglich verloren gehen. Hier kommt es auf die richtige Dosierung an, um bei Erweiterung der Periode für die Bildung des Maximalwertkompositen noch genügend zeitliche Frequenz (Wiederholrate der FE-Beobachtung) zu erhalten.

Das Prognosemodell wurde in 2 Ausführungen erstellt (siehe Abbildung 13), einmal als einfaches Modell, bei dem – vereinfacht ausgedrückt - NOAA-AVHRR-NDVI-Maximalwertkompositen nach Prozessierung den berichteten Erträgen auf Landkreisebene gegenübergestellt wurden und die daraus erstellten Korrelationsgleichungen zur Prognosemodellierung genutzt wurden. In der zweiten Ausführung (erweitertes Modell) wurden zusätzliche Submodelle zur Bestimmung von Trocken- und Temperaturstress erstellt und einbezogen. Zur Bildung des Faktors für Trockenstress gehen zudem Bodeninformationen in das Submodell ein.

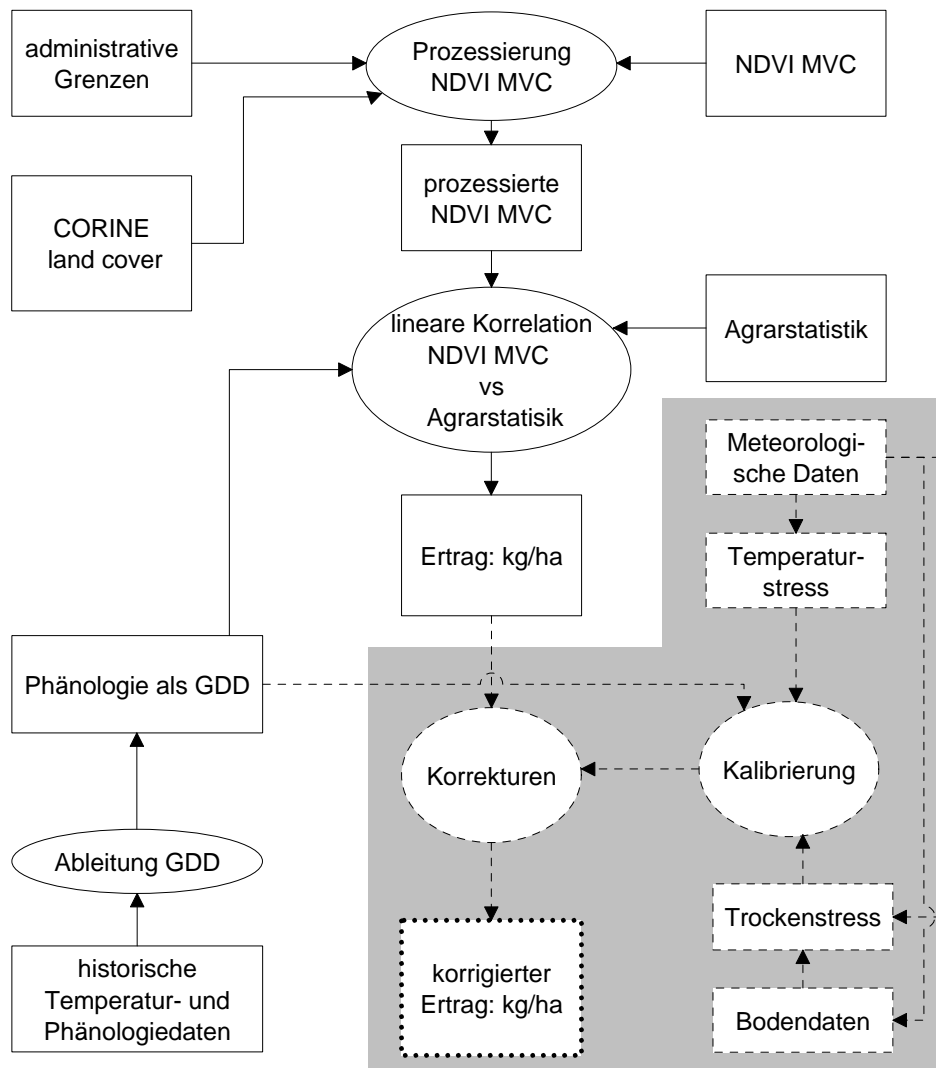


Abbildung 13: Schematische Darstellung des einfachen und erweiterten Ernteprognosemodells. Durchgehende Linien bezeichnen Datenflüsse für das einfache Modell. Die unterbrochenen Linien bezeichnen die ergänzenden Datenflüsse des erweiterten Modells (grau hinterlegt).

4.4.1 Phänologie

Um zwischen verschiedenen Jahren jeweils denselben phänologischen Zeitraum zu betrachten, ist die Kenntnis der Eintritts- und Abschlusstermine wichtiger Entwicklungsphasen eine wesentliche Voraussetzung. So ist z. B. die Dauer der Kornfüllung bei der Abschätzung der Erträge eine hilfreiche Größe. Der Deutsche Wetterdienst (DWD) berichtet die Eintrittstermine wichtiger phänologischer Entwicklungsstadien (siehe Tabelle 7, S. 52). Es erfolgt eine Einteilung in sogenannte Naturraumgruppen, innerhalb derer nur von geringen Schwankungen der beobachteten Kulturen ausgegangen wird. Die Beobachtungsrichtlinien von Jahres- und Sofortmeldern sind jedoch verschieden (DWD, 1997), sodass sich die gemeldeten Eintrittstermine leicht unterscheiden. Bis 1990 wurden diese phänologischen Termine auch für die Sommergerste berichtet. Prinzipiell ließen sich phänologische Daten auch über Korrelationen zu anderen berichteten Kulturen herleiten (HÜNTING et al., 2003; SCHELLING, 2000). Ein weiterer Nachteil der Verwendung von DWD-

Phänologiedaten ist die notwendige und fehleranfällige Regionalisierung, der diese Daten unterzogen werden müssten, um mit meteorologischen Daten verknüpft werden zu können, nachdem sich beide Originaldaten nicht auf dieselben Räume beziehen. Aufgrund erwarteter Fehler und Inkonsistenzen in diesen Daten verwendet der vorliegende Modellansatz Temperatursummen (*Growing Degree Days – GDD*) als indirekte phänologische Information. Anhand von GDD (über eine bestimmte Anzahl von Tagen ermittelte Temperatursumme) kann für die jeweiligen Untersuchungsjahre die phänologische Entwicklung anhand des Temperaturverlaufs rekonstruiert werden. Damit kann näherungsweise das Eintrittsdatum in eine bestimmte phänologische Phase ermittelt werden.

$$GDD = \frac{T_{\max} - T_{\min}}{2} - T_{\text{Basis}} \quad [9]$$

Vom Mittel der täglichen Maximaltemperaturen (T_{\max} bzw. T_{\min}) wird die Basistemperatur (T_{Basis}) abgezogen, die im konkreten Fall 3 °C beträgt. Dieser Wert wird häufig für Getreide angenommen, da pflanzenphysiologische Aktivitäten unter dieser Temperatur kaum vorhanden sind. Die erhaltenen täglichen GDD werden dann kumulativ zu Temperatursummen aufsummiert. Im vorliegenden Fall mussten zur Berechnung der GDD die Temperaturmittelwerte herangezogen werden, da nicht beide Temperaturextreme verfügbar waren. Somit ergab sich für die täglichen GDD im vorliegenden Fall:

$$GDD = T_{\text{mean}} - T_{\text{Basis}} \quad [10]$$

Dies ist insofern zulässig, als für alle Anwendungen nach derselben Berechnungsmethode verfahren wurde.

Um die Temperatursummen, bei der die entsprechenden phänologischen Termine eintreten, zu ermitteln, wurden Daten derjenigen Klimastationen und der phänologischen Stationen gewählt, die in unmittelbarer Nähe und auf gleicher Höhenstufe lagen. Konkret eigneten sich solche Stationen, die weniger als 50 m Höhenunterschied aufwiesen und innerhalb eines Radius von maximal 10 km lagen. Berücksichtigt wurde der Zeitraum, in dem die Phänologie der Sommergerste auch tatsächlich vom DWD berichtet wurde (1987 - 1990). Die Gegenüberstellung wurde aufgrund der Höhenunterschiede für die Regionen RLP und BW getrennt durchgeführt. Für BW ist sie in Abbildung 14 dargestellt.




Abbildung 14: Temperatursummen (*Growing Degree Days – GDD*) in Abhängigkeit des Julianisches Tages für die Eintrittsdaten 5 phänologischer Stadien. Das jeweils größere Symbol stellte den räumlichen Median (*Center of minimum distance – R. Median*) für das entsprechende phänologische Stadium dar. Abgebildet sind Daten aus ausgewählten phänologischen und meteorologischen Stationen in der Untersuchungsregion BW der Jahre 1987-1990. Das Bestimmtheitsmaß über alle phänologischen Phasen für die lineare Funktion liegt bei $R^2 = 0,93$.

Zur Bestimmung der konkreten Temperatursumme wurde aus den ermittelten Punktwolken des jeweiligen phänologischen Stadiums der „räumliche“ Median gebildet. Der räumliche Median kann als der Punkt interpretiert werden, an dem die summierte Distanz zwischen allen anderen Punkten und dem räumlichen Median minimiert wird. Die Position des räumlichen Medians kann rechnerisch nur mit Hilfe eines iterativen Algorithmus approximiert werden (LEVINE, 1999). Der räumliche Median ist jener Punkt (U, V), der den folgenden Ausdruck minimiert.

$$\sum_{i=1}^N \sqrt{(X_i - U)^2 + (Y_i - V)^2} \rightarrow \text{Minimum} \quad [11]$$

- N Anzahl der Punkte
- (X_i, Y_i) i -te Punktcoordinate
- U X-Koordinate des räumlichen Medians
- V Y-Koordinate des räumlichen Medians

Tabelle 7: Phänologische Phasen und ihr Eintritt nach Kalendertag (Julianischer Tag - JD) bzw. nach ermittelten Temperatursummen (Growing Degree Day – GDD, Basistemperatur 3 ° C) für die Untersuchungsregionen in Rheinland-Pfalz (RLP) und Baden-Württemberg (BW).

Phänologische Phase	DWD-Phasenkenzahl	RLP		BW	
		JD	GDD	JD	GDD
Aussaat	25	75	184	92	118
Auflaufen	26	89	263	105	174
Schossen	27	122	489	146	473
Ährenschieben	28	159	987	168	689
Gelbreife	82	186	1378	215	1301
Ernte	192	210	1778	225	1491

Die Ergebnisse für die beiden Untersuchungsregionen sind in Tabelle 7 wiedergegeben. In der Literatur werden vergleichbare Werte für die jeweiligen Temperatursummen berichtet (RUSSELL, 1990; WILLEKENS et al., 1998), dabei ist jedoch die unterschiedliche Methodik der Berechnung zu berücksichtigen (Basistemperatur).

Da die Höhenunterschiede der untersuchten Stationen beider Untersuchungsregionen mit ca. 450 m beachtlich sind, bot es sich an, anhand zweier getrennter GDD-Skalen vorzugehen. Eine einfache Standardisierung der GDD über die Höheninformation und einem angenommenen Temperaturgradienten (z. B. $0,6 \text{ °C } 100 \text{ m}^{-1}$) allein reicht nicht aus, da die phänologische Entwicklung auch von anderen Einflüssen, wie beispielsweise von den Effekten des Photoperiodismus abhängig ist.

Die Temperaturdaten lagen als Punktdaten repräsentativer Klimastationen für jeden Landkreis vor. Die Transformation in flächige Information erfolgte aufgrund der relativ geringen Anzahl an Datenpunkten je Landkreis durch arithmetische Mittelung.

4.4.2 NDVI-Akkumulation

Als NDVI-Akkumulation wird die Integration von NDVI-Werten über eine bestimmte Zeitspanne bezeichnet. Da es sich bei der „Integration“ aufgrund der diskreten Tagesintervalle um kein echtes Integral im mathematischen Sinne handelt, sondern um ein „Pseudo-Integral“, wird der Begriff NDVI-Akkumulation bevorzugt.

Die Korrelationen zwischen Ertrag und NDVI-Summen sind nach DADHWAL & SRIDHAR (1997) sowie ECKERT & KELLENBERGER (2001) besonders zum Zeitpunkt der maximalen photosynthetischen Aktivität hoch. Dieser Zeitpunkt wurde aus FE-Daten (LANDSAT) annähernd bestimmt, sodass die NDVI-Summen zu diesem Zeitpunkt akkumuliert werden können. Dieser Termin liegt etwas später als das Eintrittsdatum des phänologischen Stadiums der Blüte (siehe Abbildung 15 und Abbildung 16).

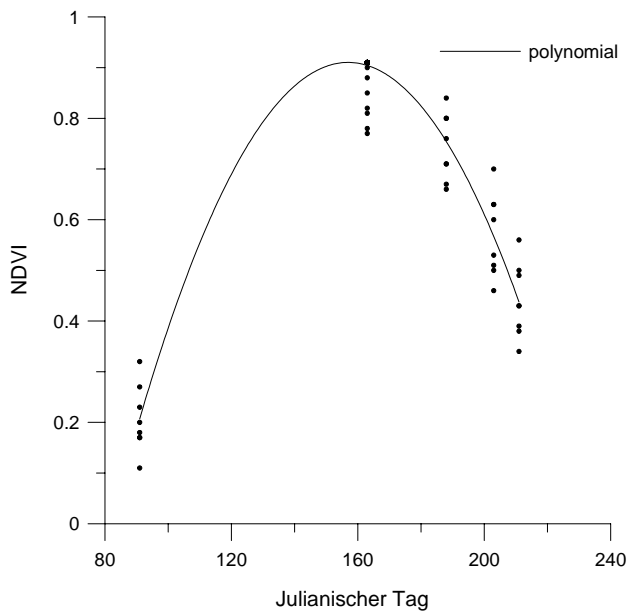


Abbildung 15: Entwicklung des NDVI in Abhängigkeit der Kalendertage (Julianischer Kalender) für die Untersuchungsregion BW (Polynom 2. Grades, $R^2 = 0,96$). Die Daten stammen aus LANDSAT-Daten des Jahres 2001. Um die Anpassungskurve annähernd durch das NDVI-Maximum zu zwingen, wurde dieses 100-fach höher gewichtet.

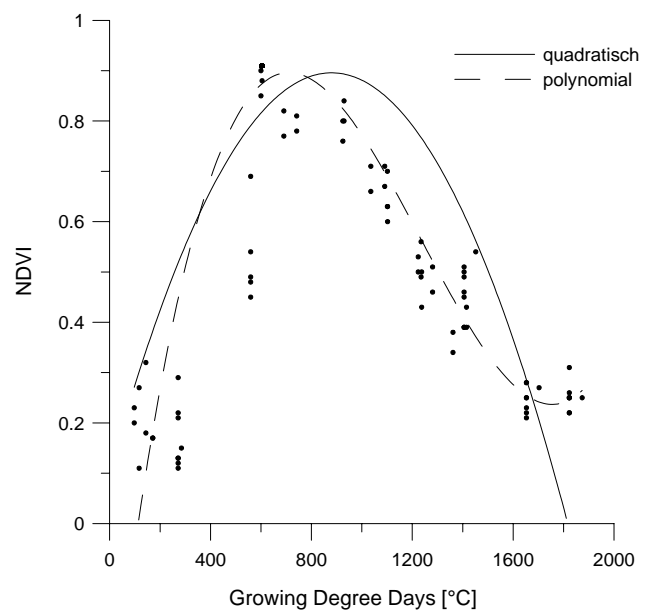



Abbildung 16: Entwicklung des NDVI in Abhängigkeit der Temperatursumme (*Growing Degree Days*) für die Untersuchungsregionen BW und RLP. Die Daten stammen aus LANDSAT-Daten des Jahres 2001. Durch ein Polynom 3. Grades ($R^2 = 0,87$) ließ sich eine bessere Anpassung erzielen als durch eine Quadratfunktion ($R^2 = 0,67$). Um die Anpassungskurve annähernd durch das NDVI-Maximum zu zwingen, wurde dieses 100-fach höher gewichtet.

Grundsätzlich lässt sich die Akkumulation des NDVI mit oder ohne Berücksichtigung der Phänologie durchführen. Die Akkumulation anhand von Kalenderperioden hat den Vorteil der Einfachheit. Die unterschiedliche phänologische Dynamik des Jahresverlaufes wird dabei nicht berücksichtigt. Wird die Phänologie mit einbezogen, kann dies über die phänologischen Meldedaten des DWD erfolgen bzw., indirekt, über *Growing Degree Days*. Im vorliegenden Fall wurde für die Akkumulation der NDVI-Summen der Ansatz über die *Growing-Degree-Days* gewählt (siehe 4.4.1).

Zu Vergleichszwecken wurde der NDVI sowohl anhand von starren Kalendereinheiten als auch anhand von GDD aggregiert (siehe Abbildung 17 bzw. Tabelle A 9 im Anhang).

Besonders signifikante Zusammenhänge zwischen NDVI und Ertrag wurden in der Literatur berichtet (siehe Kapitel 2.3.2), dementsprechend wurden die Akkumulationsphasen gewählt. Die in Abbildung 17 als Linien dargestellte Akkumulationsperioden umfassen jeweils 4 Perioden für Kalendereinheiten als auch für GDD. Als Kalenderperioden wurden bereits von SCHELLING

(2000) ähnliche Perioden gewählt, wobei dieser Autor im Juni und Juli die besten Ergebnisse erzielte. Die GDD-basierten Akkumulationsperioden wurden entsprechend den berichteten phänologischen Eintrittsphasen des DWD gewählt. Diese Termine wurden genutzt, um die äquivalenten Temperatursummen (GDD) zu bestimmen (vergl. Kapitel 4.4.1). Zusätzlich wurde als Akkumulationsperiode GDD3 entsprechend den Erkenntnissen aus Kapitel 4.4.2 die Periode der „erwarteten maximalen photosynthetischen Aktivität“ bestimmt (vergl. im Anhang Tabelle A 9, siehe auch NDVI-Verlauf in Abbildung 15, Abbildung 16 und Abbildung 17).



*) GDD3: umfasst die Periode der erwarteten maximalen photosynthetischen Aktivität

Abbildung 17: NDVI-Jahresverlauf, errechnet aus gemittelten „synthetischen täglichen“ AVHRR-NDVI-Daten aus beiden Untersuchungsregionen sowie berücksichtigte Zeiträume, über welche NDVI-Summen gebildet wurden. Mit Kal bezeichnete Zeitspannen sind über Kalendertage akkumuliert, mit GDD bezeichnete Zeitspannen mittels GDD. Zu beachten ist, dass es sich für GDD1 bis GDD4 um ungefähr dargestellte Zeitangaben handelt, da diese Zeitspannen auf Temperatursummen beruhen, welche nicht in allen Landkreisen denselben Kalendertagen entsprechen.

4.4.3 Einfaches Prognosemodell – Funktionsweise

NOAA-AVHRR-NDVI-Wochenkompositen unterlagen einer Prozessierung, die in Kapitel 4.1.2 beschrieben ist (siehe auch Abbildung 18). Um die AVHRR-NDVI-Pixel auf diejenigen einzuschränken, die für eine Ernteprognose relevant erscheinen, wurde auf die europäischen *CORINE*-Daten zurückgegriffen. Mit der Klasse „*non-irrigated arable land*“ von *CORINE land cover* wurde eine Ackermaske erzeugt, womit die NOAA-AVHRR-Daten auf die aussagekräftigsten Pixel reduziert werden konnten. Durch Überlagerung der entsprechenden administrativen Einheiten (Zonen), im konkreten Fall der Kreisgrenzen, konnte der jeweilige zonale Median je *layer* der ein Jahr umfassenden NDVI-*Multilayer* berechnet werden. Dabei wurden verbleibende Restwolken von der Berechnung ausgeschlossen. Die resultierenden Werte, die mittlere NDVI-Maximalwerte für einen Landkreis und über einen Zeitraum von (im Normalfall) 14 Tagen beinhalteten, wurden anschließend auf synthetische Tageswerte skaliert und in einer Datenbank abgelegt. Damit entstand eine Datenbasis, in der für die Jahre 1995 bis 2002 je Landkreis und je Tag ein synthetischer NDVI-Wert steht, der über beliebig wählbare Zeiträume akkumuliert werden kann (siehe Abbildung 17). Die Bildung von synthetischen Tageswerten ist deshalb unumgänglich, da die echten NDVI-Werte aus 2-Wochenkompositen nicht jedes Jahr auf dieselben Tage fallen und dadurch Inkonsistenzen entstehen, die eine korrekte interannuelle Abfrage nicht zulassen. Um die NDVI-Werte nicht zu verfälschen, wurde bewusst auf eine nachträgliche Glättung der Tageswerte verzichtet. Eine detaillierte Darstellung des Datenflusses ist in Abbildung 18 zu sehen.

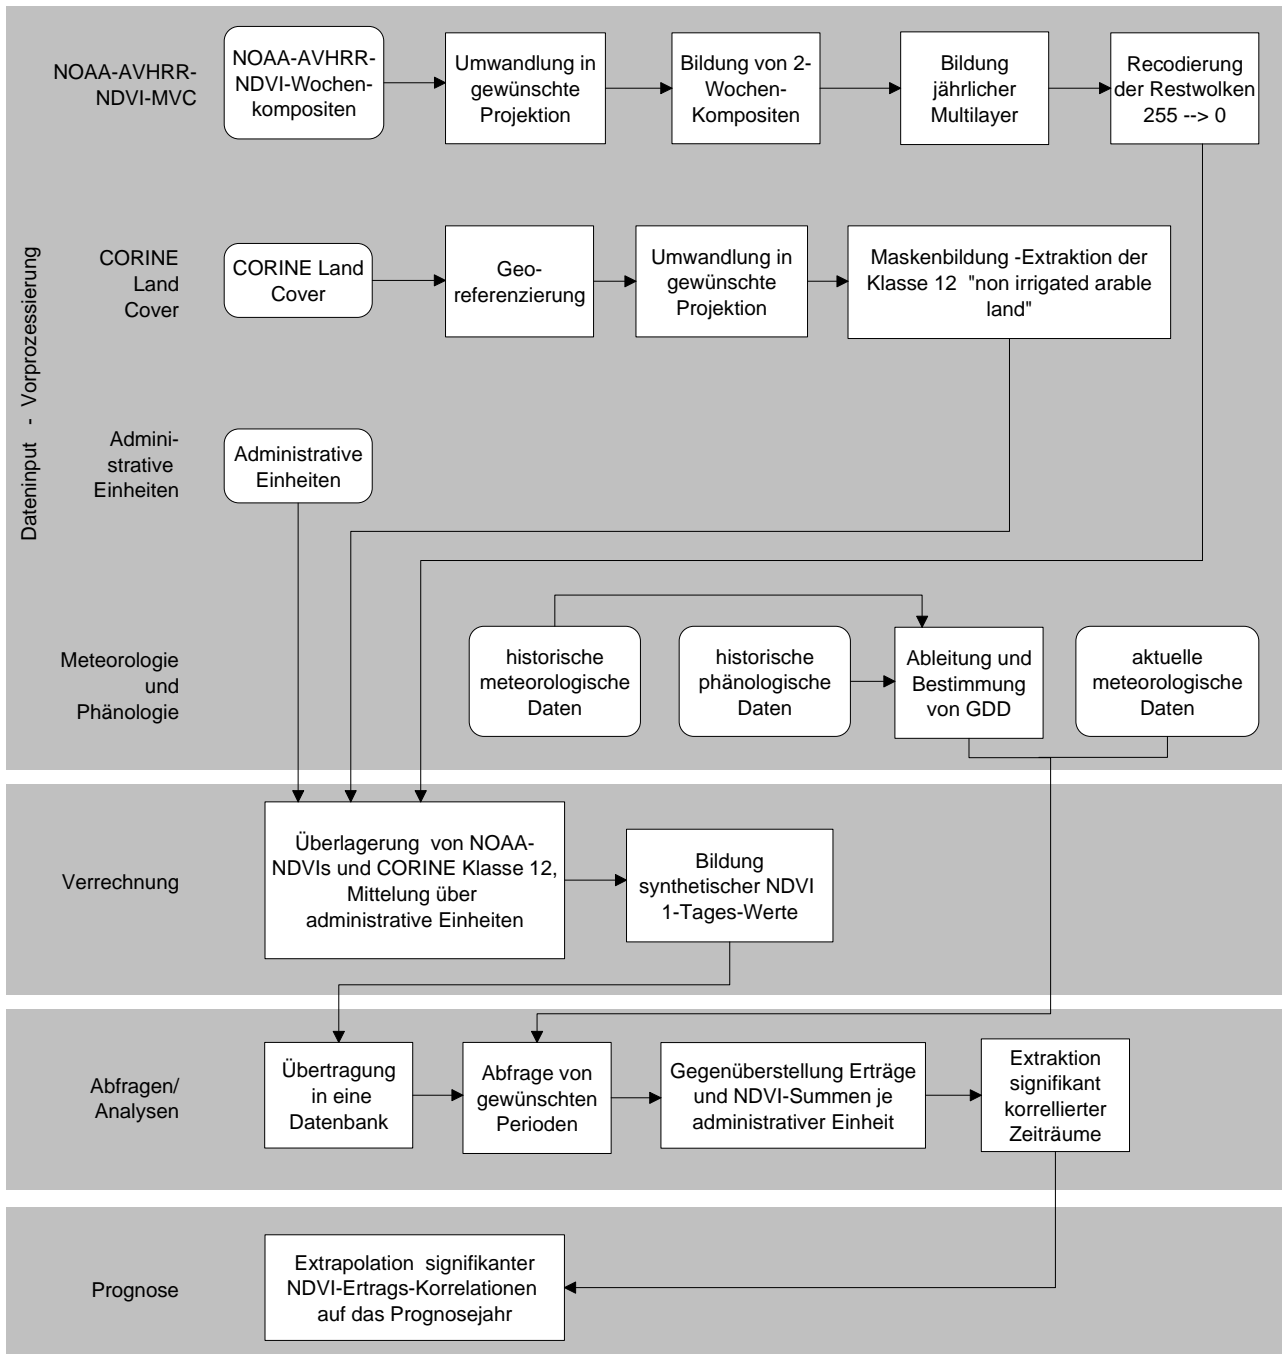


Abbildung 18: Datenflüsse des einfachen Ertragsprognosemodells mit NOAA-AVHRR.

Die nun mögliche Abfrage von gewünschten Perioden orientiert sich an *Growing Degree Days*, die über historische phänologische und meteorologische Daten der Untersuchungsregionen abgeleitet wurden (siehe 4.4.1). Die Korrelationen können für verschiedene Aggregationszeiträume erstellt werden, in denen NDVI-Werte akkumuliert werden und den berichteten Erträgen gegenübergestellt werden. Mit der NDVI-Aggregation wird sowohl der zeitlichen Ausdehnung als auch der Intensität des NDVI Rechnung getragen (Pseudo-Integral). Wird nun ein besonders signifikanter Zeitraum gefunden, können anhand der linearen Korrelation zum chronologischen Ende dieses Aggregationszeitraumes Ertragsprognosen errechnet werden.

4.4.4 Erweitertes Prognosemodell – Funktionsweise

Das erweiterte Prognosemodell baut auf dem einfachen Modell modular auf. Die Erweiterung umfasst die Integration von Stressfaktoren für Trocken- bzw. Temperaturstress. Die über das einfache Prognosemodell errechneten Erträge erfahren über Faktoren für Trocken- bzw. Temperaturstress, die in 2 getrennten Submodellen berechnet wurden, eine nachträgliche Anpassung, die in einer Auf- bzw. Abwertung von Erträgen besteht. Damit sollten jene Umstände berücksichtigt werden, die sich nicht notwendigerweise in der NOAA-AVHRR-Aufnahme abbilden und deshalb als Wirkungsfaktoren nicht ausreichend zur Geltung kommen könnten. Besonders sensitiven Entwicklungsstadien kommt eine sorgfältige Beachtung zu: Die berücksichtigten phänologischen Phasen umfassen den Zeitraum zwischen Aussaat und Auflaufen (AS - AL), die Phase zwischen Schossen und Ährenschieben (SCH - ÄS) sowie die Kornfüllungsphase zwischen Ährenschieben und Gelbreife (ÄS - GR). Die Effekte von Temperatur und Trockenheit auf die Sommer- bzw. Braugerste wird u. a. bei SCHELLING (2000) sowie bei LOOMIS und CONNOR (1992) diskutiert.

Abbildung 19 zeigt den schematischen Aufbau des erweiterten Ertragsprognosemodells. Das linke Kompartiment zeigt die Modellierung des Ertrages, wie sie analog im einfachen Ertragsprognosemodell angewandt wird. Das mittlere und rechte Kompartiment stehen für die Modellierung von Trocken- bzw. Temperaturstress, deren Ergebnisse in die Korrekturen für den über NOAA-AVHRR modellierten Ertrag einfließen. Folgend beschrieben ist eine detaillierte Erläuterung der durchgeführten Arbeitsschritte. Die Untersuchung wurde für dieses erweiterte Modell aus Gründen der Datenverfügbarkeit auf 4 Landkreise eingeschränkt, nämlich auf einen Landkreis in der Untersuchungsregion RLP (Südliche Weinstraße - SÜW) sowie auf 3 Landkreise in BW (Freudenstadt – FDS, Rottweil – ROTT und Tuttlingen – TUTT).

Erweitertes Ertragsprognosemodell

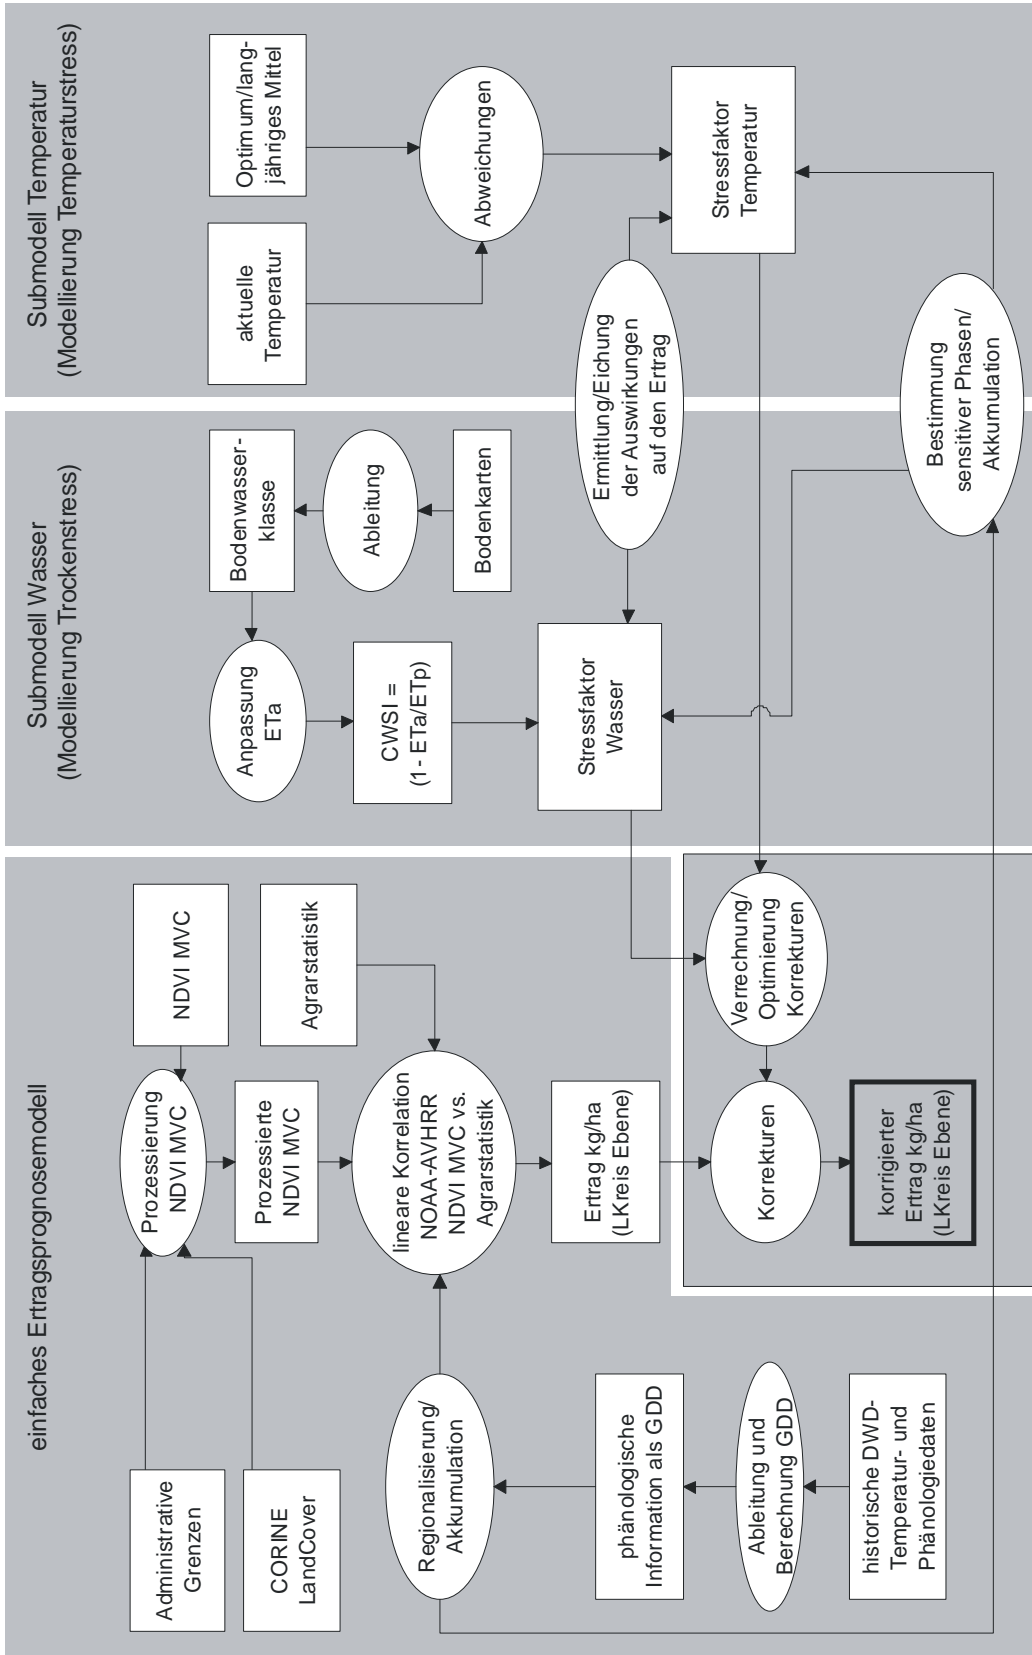


Abbildung 19: Schematische Darstellung des erweiterten Ertragsprognosemodells. Das Modell besteht aus 3 Kompartimenten, den NOAA-Regressionen (analog dem einfachen Ertragsprognosemodell) sowie 2 weiteren Kompartimenten zur Modellierung von Trocken- bzw. Temperaturstress, deren Ergebnisse in die Korrekturen des über NOAA-AVHRR modellierten Ertrages einfließen.

4.4.4.1 Bodendaten

Für das erweiterte Prognosemodell waren Daten zum Bodenwasserhaushalt notwendig, die für das Pflanzenwachstum von nachhaltigem Interesse sind. Da für die Untersuchungsregionen in BW und RLP unterschiedliche Bodeninformationen vorlagen, musste für die Modellentwicklung eine Vereinheitlichung durchgeführt werden. Es wurde eine Einteilung in 3 Klassen zum Bodenwasserhaushalt vorgenommen: Bodenwasserklasse 1 – leichter Boden, 2 – mittelschwerer Boden, 3 – schwerer Boden.

Für BW lag auf regionaler Ebene die Bodenübersichtskarte 1 : 200 000 (BÜK200) vor (GEOLOGISCHES LANDESAMT BADEN-WÜRTTEMBERG, 1994); für RLP die Übersichtskarte der Bodentypen-Gesellschaften von Rheinland-Pfalz im Maßstab 1 : 250 000 (STÖHR, 1966).

Für die Ableitung von Bodenwasserklassen, welche eine grobe Einteilung für den Bodenwasserhaushalt darstellte, musste in der Untersuchungsregion BW auf die Feldkapazität (FK) der BÜK200 zurückgegriffen werden, da der Kennwert der nutzbaren Feldkapazität (nFK) nicht vollständig kartiert war und die Klasseneinteilung für die beabsichtigten Zwecke wegen Klassenüberschneidungen ungeeignet war. Die Bodenwasserklassen wurden zunächst in 4 Kategorien eingeteilt, wobei die Klasse 0 (stark wechselnd) darauf aufgrund des Attributs der Bodenart erneut zugewiesen wurde (siehe Tabelle A 9 und Tabelle A 11). Die verbleibenden Polygone der Klasse 0 galten als Objekte, die keinen Boden darstellen und wurden daher nicht weiter berücksichtigt.

In Anlehnung an die Beschreibung der BÜK200 und an der Literatur (QUADE, 1993) konnten in der Untersuchungsregion RLP anhand der Einteilung der nFK 3 Bodenwasserklassen abgeleitet werden (siehe Anhangstabelle Tabelle A 12).

4.4.4.2 Trockenstress in Abhängigkeit der Bodenbedeckung und Bodenart

Trockenstress kann durch das Verhältnis von tatsächlicher (oder aktueller) Verdunstung (ET_a) zur potentiellen (oder maximalen) Verdunstung (ET_p oder ET_m) ausgedrückt werden. Der Komplementärwert zu 1 wird auch als *Crop Water Stress Index (CWSI)* bezeichnet:

$$CWSI = 1 - \frac{ET_a}{ET_p} \quad [12]$$

ET_a und ET_p konnten vom DWD bezogen werden. Da die Berechnung der ET_a (berechnet nach einer modifizierten Methode nach HAUDE, DVWK, 1984) u. a. von der Bodenbedeckung abhängig ist, wird diese vom DWD für verschiedene Kulturen angeboten, u. a. auch für Sommergerste.

Zusätzlich muss bedacht werden, dass der Berechnung der tatsächlichen Evapotranspiration nach dem DWD eine bestimmte Bodenart mit einer definierten nutzbaren Feldkapazität zugrunde liegt. Die angebotenen Bodenarten sind im Anhang in Tabelle A 13 aufgeführt.

Da die Bodenverhältnisse über die gesamten Untersuchungsregionen nicht einheitlich sind, kann die ET_a jeweils nur für die entsprechende Bodenart gelten. Für eine flächendeckende Berechnung müssten die Werte der ET_a für alle vorhandenen Bodenarten vorliegen. Um dies zu umgehen, wurde wie folgt vorgegangen:

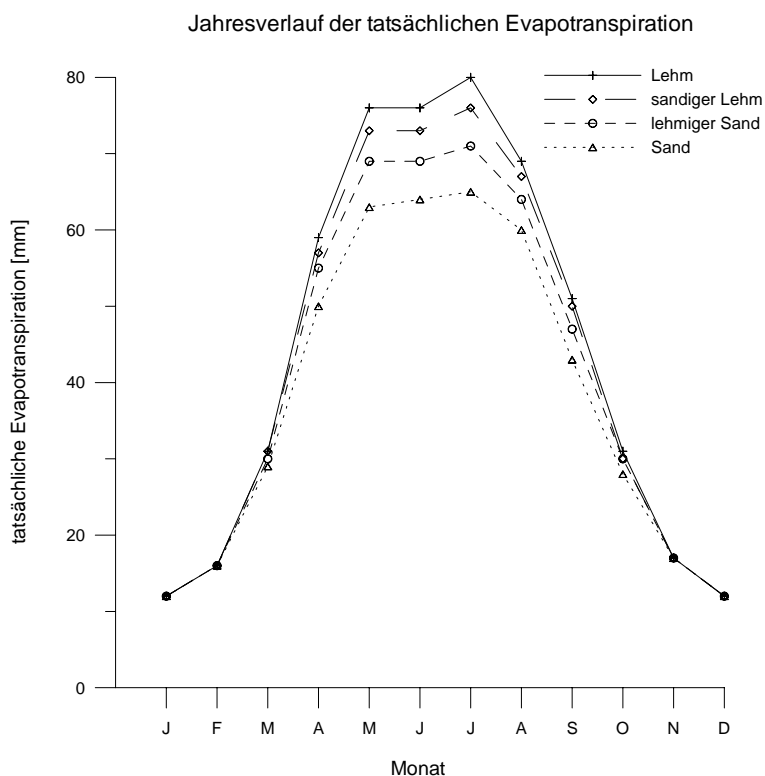


Abbildung 20: Jahresverlauf der tatsächlichen Evapotranspiration (ET_a) auf 4 Modellböden. Als Grundlage dienten Messungen der Klimastation *Badenweiler* aus den Jahren 1951 - 1980 mit der Bodenbedeckung Gras.

den Jahren 1951-1980 errechnet (DOMMERMUTH & TRAMPF, 1995). Zur Evaluierung wurden zusätzlich Daten der Wetterstation *Klippenhart* dazugezogen, die denselben tendenziellen Verlauf für die untersuchten Modellböden zeigten. DWD-Daten wurden für die Bodenart „lehmiger Sand“ verwendet, da diese Bodenart als diejenige identifiziert wurde, welche gegenüber einem leichten und einem schweren Boden hinsichtlich Entwicklung der tatsächlichen Evapotranspiration, wie Abbildung 20 zeigt, eine mittlere Position einnimmt.

Aus dem genannten Datensatz der Jahre 1951-80 wurden monatliche Korrekturfaktoren für die leichten und schweren Böden ermittelt, die im Anhang tabellarisch aufgelistet sind (Tabelle A 14).

Aus den vorhandenen Bodenarten unterschiedlicher Quellen konnten Informationen zum Bodenwasserhaushalt abgeleitet werden, die eine Einteilung in leichte, mittlere und schwere Böden zulassen. Ausgehend von der tatsächlichen Evapotranspiration für eine mittelschwere Bodenart (lehmiger Sand oder sandiger Lehm), ließen sich Korrekturfaktoren für die tatsächliche Evapotranspiration von leichten oder schweren Böden ermitteln, wodurch die Datenbeschaffung auf eine Bodenart eingegrenzt werden konnte. Die Ermittlung der Korrekturfaktoren wurde aus Daten der Wetterstation *Badenweiler* (412 m ü. N.N.) aus

Wird für den mittelschweren Boden (Bodenwasserklasse 2) die Bodenart lehmiger Sand zugrundegelegt, können für die Bodenklassen „leichte Böden“ (Bodenwasserklasse 1) und „schwere Böden“ (Bodenwasserklasse 3) die entsprechenden Umrechnungsfaktoren von lehmigen Sand auf Sand bzw. Lehm herangezogen werden (Zeile 2 und 4 der Tabelle A 14).

Obwohl die experimentellen Werte für die Bodenbedeckung Gras erstellt wurden, wird aufgrund der klimatischen Verhältnisse im Untersuchungsraum tendenziell dasselbe relative Verhalten für die untersuchte Kultur Sommergerste erwartet. Angesichts der räumlichen Auflösung der Bodenkarten mit entsprechend einhergehender Generalisierung werden unterschiedliche Schichtdicken zur Berechnung des Bodenwassergehaltes von Gras und Sommergerste vernachlässigt.

Durch die beschriebene Vorgehensweise sind im Faktor Trockenstress sowohl die Wasserverhältnisse aufgrund des Verhältnisses von tatsächlicher zu potentieller Evapotranspiration als auch die unterschiedlichen Bodenverhältnisse integriert.

Bei der Berechnung des CWSI müssen Sonderfälle beachtet werden: Aufgrund der voneinander unabhängigen Berechnung der aktuellen und potentiellen Evapotranspiration durch den DWD (vergl. Kapitel 4.2.1, Seite 36), kommt es in einigen Fällen zu einem höheren Wert der tatsächlichen Evapotranspiration als für die potentielle Evapotranspiration. In diesem Fall wird angenommen, dass kein Trockenstress vorherrscht und der *Crop Water Stress Index (CWSI)* wird gleich 0 gesetzt. Dasselbe gilt bei einem identischen Wert der tatsächlichen und potentiellen Evapotranspiration. Zu beachten sind zudem die Fälle, in denen entweder keine Daten für die tatsächliche bzw. potentielle Evapotranspiration berichtet werden bzw. die Fälle, in denen die potentielle Evapotranspiration gleich 0 beträgt. Im letzteren Fall kann anstatt 0 ein sehr kleiner Wert (10^{-5}) gewählt werden, um den Quotienten ET_a/ET_p trotzdem approximativ berechnen zu können.


Konkret gestaltete sich die Berechnung des CWSI folgendermaßen: Den Bodenpolygonen der Bodenkarte, welche als Attribut die Bodenwasserklasse enthielten, wurde der zugehörige Landkreis und die Klimastation zugewiesen, in dessen Einzugsgebiet sich das jeweilige Bodenpolygon befand. Die Einzugsgebiete der einzelnen Klimastationen konnten über die GIS-Funktionalität der Allokation (*proximity*) bestimmt werden. Aus Gründen der Einfachheit erfolgte eine diskrete Abgrenzung der Einzugsgebiete.

In einer Datenbank konnte die Berechnung der korrekten ET_a , nämlich der ET_a in Abhängigkeit der Bodenart durchgeführt werden. Nun konnte in den Fällen, in denen die ET_a größer oder gleich der ET_p ist, dem CWSI der Wert 0 zugewiesen werden, in den anderen Fällen erfolgte die korrekte Berechnung unter Beachtung der Sonderfälle. Der ermittelte CWSI lag schließlich für jedes Bodenpolygon als Tageswert vor und wurde über einen Landkreis gemittelt. Dadurch waren Abfragen des CWSI über vom GDD bestimmte phänologische Zeiträume möglich.

Die Daten lagen für den Zeitraum von 1990 bis 2002 vor. Für diesen 13-jährigen Zeitraum wurde der mittlere Wert des CWSI für die phänologischen Phasen, die in Tabelle 7 angeführt sind, je Landkreis bestimmt.

4.4.4.3 Quantifizierung der Auswirkungen von Trockenstress

Eine Quantifizierung der durch Trockenstress verursachten Ertragseinbußen zeigen DOORENBOS & KASSAM (1979) auf. Demnach sind die erlittenen Ertragseinbußen sowohl von der Pflanzenart als auch vom Zeitpunkt des Auftretens des Trockenstresses abhängig. Die FAO-Phänologie-Phasen „Blüte“ und „Ertragsbildung“ werden dabei als besonders empfindlich eingestuft. Diese Stadien entsprechen den EC-Stadien 60-69 (Blüte) bzw. EC 70-80 und EC 81-90 für frühe und späte Ertragsbildung (DEMIRCAN, 1995). Wesentlich geringere Ertragseinbußen sind dagegen in der vegetativen Phase sowie im Reifestadium bei Trockenstress zu erwarten. Die Quantifizierung der Ertragseinbußen kann durch die Beziehung, die in Gleichung [2] beschrieben wird (siehe Kapitel 2.3.1), bestimmt werden, indem der CWSI eingesetzt wird (siehe Gleichung [12], Kapitel 4.4.4.2).



Da die FAO (DOORENBOS & KASSAM, 1979) keine Angaben für Sommergerste macht, wurden die Werte für Sommerweizen herangezogen, die für k_y in den FAO-Phänologiestadien Blüte und Ertragsbildung mit 0,55 bzw. 0,65 angegeben werden (vergl. k_y oder *yield response factor*, Gleichung [2], Seite 10). Da die untersuchte phänologische Phase vom ÄS bis zur GR reicht und somit beide FAO-Phasen beinhaltet, wurde das Mittel gebildet welches bei $k_y = 0,60$ liegt. Das bedeutet, dass für das phänologische Stadium der Kornfüllung mit einer Ertragsminderung des maximal erwarteten Ertrages um 60 % des CWSI zu rechnen

ist. Für die phänologische Phase zwischen SCH und ÄS wurde für k_y der Wert 0,2 herangezogen.

Nach Berechnung des CWSI mit Hilfe der Bodenkarten und der DWD-Daten konnte der durchschnittliche CWSI für eine phänologische Phase bestimmt werden. Damit konnte der Ertragsverlust vom Maximalertrag (V_{Ym}) je Landkreis quantifiziert werden.

$$V_{Ym} = CWSI \cdot k_y \quad [13]$$

Um diesen Ertragsverlust auf den tatsächlich erwarteten Ertrag zu skalieren, wurde das Verhältnis von vorläufig modelliertem (aus einfachem Ertragsprognosemodell) zu maximalem Ertrag genutzt. Dafür wurden die maximalen Erträge der Landkreise der Jahre 1990 bis 2002 herangezogen.

$$V_{Ya} = V_{Ym} \cdot \frac{Y_a}{Y_m} \quad [14]$$

Eingeführt wurde zudem eine Variable, mit der das Ausmaß der Korrektur für Trockenstress freigestellt werden konnte (0 – 100 % Korrektur). Mit diesem Parameter konnte das Modell optimiert werden.

4.4.4.4 Quantifizierung der Auswirkungen von Temperaturstress

Mit steigenden Temperaturen nach der Blüte sinken die Kornerträge von Weizen (WHEELER et al., 1996) und Gerste (u. a. EAGLES et al., 1995). Der Ertragsrückgang wird bei WARDLAW (1989) mit 3 – 4 % je 1 °C Temperaturanstieg über einer Tagesmitteltemperatur von 15 °C beziffert. Dieser Ansatz wurde für die Korrektur in der Kornfüllungsphase herangezogen; in Voruntersuchungen führten bereits Einfachkorrelationen zwischen Ertrag und Temperaturen über 15 °C zu signifikanten Ergebnissen. Die Quantifizierung der Ertragseinbußen für Temperaturstress in den phänologischen Phasen zwischen Aussaat und Auflaufen sowie zwischen Schossen und Ährenschieben beruhen zunächst auf Schätzungen. Dabei wurde davon ausgegangen, dass das Verlustpotential generell niedriger als in der Kornfüllungsphase liegt. Die Annahme erfolgte mit 2 % je 1 °C Temperaturabweichung vom langjährigen Temperaturmittel (Median). Diese Annahmen relativieren sich jedoch im folgenden Optimierungsprozess, in der die Dimensionierung der unterschiedlichen Korrekturfaktoren für Stress erfolgte. In diesem Schritt konnte die Dimensionierung der Korrektur der berechneten Ertragsverluste durch Temperaturstress analog zu denen für Trockenstress reguliert werden (0 - 100 %).

4.4.4.5 Angewandte Korrekturen für Temperatur- und Trockenstress

Zur Korrektur des mittels NOAA-AVHRR-NDVI prognostizierten Ertrages wurden die in Tabelle 8 beschriebenen Auf- bzw. Abwertungen angewendet:

Tabelle 8: Beschreibung der eingesetzten Korrekturfaktoren für Stress

Korrektur	Stress	Phänologische Phase	Beschreibung
1	Temperatur	AS – AL	Temperaturüberschüsse oder –defizite des Landkreismittels (Median) führen zu Auf- bzw. Abwertungen des modellierten Ertrages von $2 \% \text{ } ^\circ\text{C}^{-1}$.
2	Temperatur	SCH – ÄS	Temperaturüberschüsse oder –defizite des Landkreismittels (Median) führen zu Ab- bzw. Aufwertungen des modellierten Ertrages von $2 \% \text{ } ^\circ\text{C}^{-1}$.
3	Trockenheit	SCH – ÄS	Relative Evapotranspirationsdefizite (CWSI) führen zu einem über den <i>yield response factor</i> (0,2) dimensionierten Minderertrag von Maximalerträgen des Landkreises (DOORENBOS & KASSAM, 1979).
4	Temperatur	ÄS – GR	Temperaturüberschüsse oder -defizite einer Basistemperatur von $15 \text{ } ^\circ\text{C}$ führen zu Ab- bzw. Aufwertungen des modellierten Ertrages von $3,5 \% \text{ } ^\circ\text{C}^{-1}$ (WARDLAW et al., 1989).
5	Trockenheit	ÄS – GR	Relative Evapotranspirationsdefizite (CWSI) führen zu einem über den <i>yield response factor</i> (0,6) dimensionierten Minderertrag von Maximalerträgen des Landkreises (DOORENBOS & KASSAM, 1979).

Während Angaben für die Quantifizierung der Korrekturen 3, 4 und 5 aus der Literatur gewonnen werden konnten, sind die quantitativen Angaben der Mindererträge für die Korrekturen 1 und 2 zunächst angenommen. Aufgrund der darauf folgenden Optimierung des jeweiligen Dimensionierungsfaktors relativieren sich diese Annahmen, da sie aufgrund der Verknüpfung mit dem Dimensionierungsfaktor indirekt als Startwerte der Optimierung betrachtet werden können, und damit einer Veränderung in Richtung Optimum unterliegen. Durch die Optimierung sollte die ideale Bemessung der Stressfaktoren (geregelt über den Dimensionierungsfaktor) eruiert werden, indem die Differenzen historisch berichteter und simulierter Erträge minimiert wurden. So sollten sich Gesetzmäßigkeiten ableiten lassen, die Rückschlüsse auf die zukünftige Dimensionierung der Stressfaktoren ziehen lassen. Des weiteren soll durch die Optimierung die Quantifizierung der Stressauswirkung, die für das isolierte Auftreten eines Stresses gelten, im Verbund berücksichtigt werden. Abbildung 22 symbolisiert dies schematisch.

Simplex-Methode

Die *Simplex*-Methode von NELDER & MEAD (1965) ist eine direkte Suchmethode zur Minimierung einer Funktion von n Parametern. Ein Simplex ist eine geometrische Figur in einem n -dimensionalen Raum mit $n + 1$ Eckpunkten. In 2 Dimensionen ist es ein Dreieck, in 3 Dimensionen ein Tetraeder. Jede Dimension stellt einen Parameter dar, der optimiert werden soll.

Im vorliegenden Fall soll die Differenz von beobachtetem zu simuliertem Ertrag (y) minimiert werden, indem die 5 Dimensionierungsfaktoren der Stresskomponenten (D_1, D_2, D_3, D_4, D_5) angepasst werden. Das Simplex wird gebildet, indem Schätzungen für die Parameter $D_1 \dots, D_5$ eingesetzt werden, und, indem auf Basis einer typischen Skalierung den Seiten des Simplex eine Länge zugeordnet wird. Nun wird der zu minimierende Wert y an jedem der Eckpunkte geprüft und der Eckpunkt mit dem höchsten Wert wird ersetzt. Auf diese Weise entsteht in jedem Zyklus ein neues Simplex, solange, bis die Minimierung konvergiert (MODELKINETIX, 2000).

Es ist anzumerken, dass durch die Einführung des Dimensionierungsfaktors der Korrekturen, welcher an die jeweilige Korrektur 1 - 5 im Modell gekoppelt ist, weder zur quantitativen Annahme der Stressauswirkung noch zum Dimensionierungsfaktor selbst eine eindeutige Zuordnung der Auf- bzw. Abwertungen möglich ist. Die Auf- bzw. Abwertungen sind das Produkt aus beiden Faktoren, nämlich aus den Angaben zur quantitativen Stressauswirkung sowie aus dem Dimensionierungsfaktor dieser jeweiligen Korrektur (siehe Abbildung 22). Wird ein quantitativer Wert falsch angenommen, kann dieser indirekt über einen veränderten Dimensionierungsfaktor dieser Korrektur ausgeglichen werden. Die

Dimensionierungsfaktoren stellen Modellparameter dar und wurden, ausgehend von plausiblen Startwerten, die in Einfachkorrelationen ermittelt wurden, in einem weiteren Schritt über ein mathematisches Verfahren (Simplex-Methode - MODELKINETIX, 2000; NELDER & MEAD, 1965) optimiert, sodass die Abweichungen zwischen modellierten und berichteten Erträgen minimiert wurden (siehe Kasten: *Simplex*-Methode). Die errechneten Werte der Parameter für den Korrekturanteil (Dimensionierungsfaktoren) sind in Tabelle 9 dargestellt.

Tabelle 9: Optimierte Parameter (Dimensionierungsfaktor) für für 4 Landkreise.

Korrektur	SÜW	FDS	ROTT	TUTT
dimensionslose Einheiten [0 – 1]				
1	0,1435	0,4284	0,0714	0
2	0,0067	0,8891	0,0002	0,0033
3	0,2206	0	0	0
4	0,0067	0,0456	0,2314	0,0118
5	0,0011	0	0	0,0001

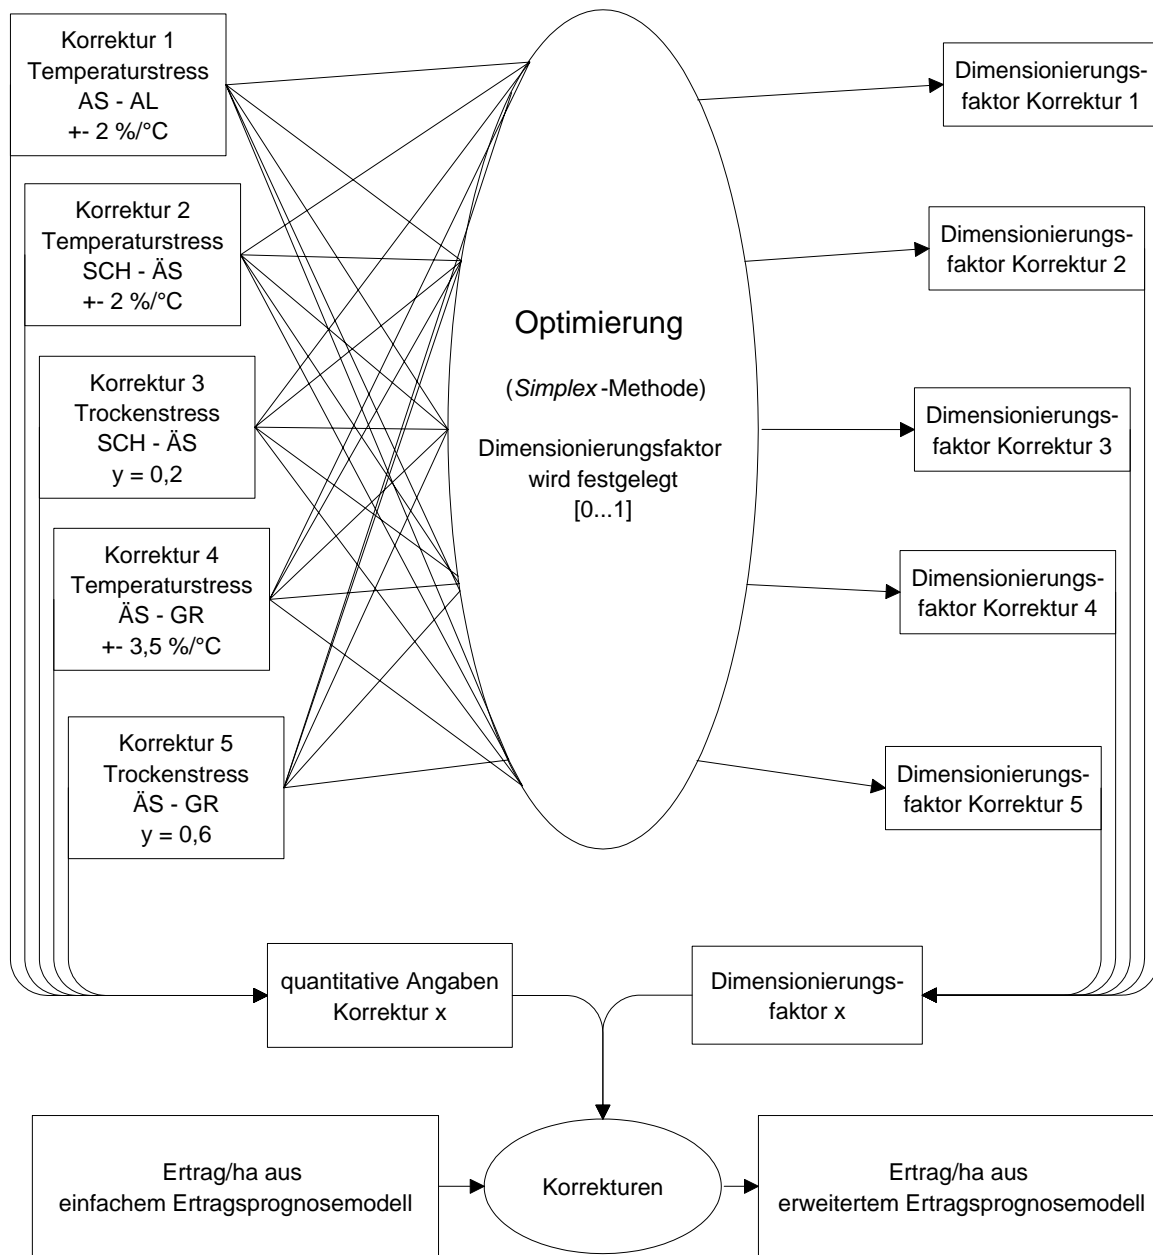


Abbildung 22: Optimierung der Stresskorrekturen anhand der *Simplex*-Methode: Ausgehend von den quantitativen Korrekturfaktoren wird – unter Berücksichtigung der Interaktionen zwischen den Korrekturfaktoren – die Dimensionierung der einzelnen Faktoren bestimmt. In die Korrektur fließen die jeweiligen quantitativen Werte für die Korrektur und der Dimensionierungsfaktors ein.

5 Ergebnisse und Diskussion

5.1 Klassifikationsergebnisse

Die Klassifikation erfolgte auf Basis zweier verschiedener Algorithmen: Obwohl der pixelbasierte und der objektorientierte Klassifikationsansatz nicht identisch ausgeführt wurden, erlaubt ein Vergleich die Prüfung des tendenziellen Klassifikationsverhalten beider Methoden.

Die bei der objektorientierten Klassifikation berechnete Segmentierung ergab mittlere Objektgrößen von 0,69 ha in RLP und 0,72 ha in BW. Größere und mittlere Schläge setzten sich somit aus mehreren Segmenten zusammen, während die kleineren Schläge nur aus 1 - 2 Segmenten bestanden.

Aufgrund der geringen Schlaggröße in Südwestdeutschland wurden die Klassifikationsergebnisse zusätzlich zu allen Feldgrößen separat für verschiedene Mindestfeldgrößen (1; 1,5 und 2 ha) berechnet. Durch diese Statistik sollte die erzielte Genauigkeit besser verdeutlicht werden als durch die klassische Fehlermatrix. Für die Prüfung der Treffergenauigkeit galt die Klassifikation eines einzelnen Schlages dann als erfolgreich, wenn mindestens 50 % oder 60 % der Fläche mit den entsprechenden Pixel bedeckt war. Neben dem Anteil der klassifizierten Schläge wurde die Klassifikationsgenauigkeit auch in Flächenanteilen angegeben (Tabelle 10 und Tabelle 11). Als unabhängige Referenzdaten wurden ATKIS-Daten herangezogen. Die Fehlermatrizen der Vorklassifikation als Vorstufe der pixelbasierten Klassifikation sind dem Anhang zu entnehmen (Tabelle A 5 und Tabelle A 6).

Tabelle 10: Ergebnisse der pixelorientierten Klassifikation in beiden Untersuchungsgebieten. Die Ergebnisse sind als Anzahl klassifizierter Schläge sowie als klassifizierte Fläche wiedergegeben. Die Schläge galten als klassifiziert, wenn mindestens 50 % oder 60 % der Fläche richtig klassifiziert wurden.

Statistik angewandt auf	Untersuchungsregion RLP				Untersuchungsregion BW			
	Anteil klassifizierte Schläge			klassifizierte Fläche	Anteil klassifizierte Schläge			klassifizierte Fläche
	Pixeldeckung				Pixeldeckung			
	n	> 50 %	> 60 %		n	> 50 %	> 60 %	
alle Schläge	92	37 %	30 %	46 %	29	62 %	55 %	58 %
Schläge > 1,0 ha	60	48 %	38 %	49 %	20	70 %	65 %	61 %
Schläge > 1,5 ha	33	61 %	45 %	57 %	11	91 %	82 %	69 %
Schläge > 2,0 ha	22	73 %	55 %	61 %	7	100 %	86 %	72 %

Tabelle 11: Ergebnisse der objektorientierten Klassifikation in beiden Untersuchungsgebieten. Die Ergebnisse sind als Anzahl klassifizierter Schläge sowie als klassifizierte Fläche wiedergegeben. Die Schläge galten als klassifiziert, wenn mindestens 50 % oder 60 % der Fläche richtig klassifiziert wurden.

Statistik angewandt auf	Untersuchungsregion RLP				Untersuchungsregion BW			
	Anteil klassifizierte Schläge			klassifizierte Fläche	Anteil klassifizierte Schläge			klassifizierte Fläche
	Pixeldeckung				Pixeldeckung			
	n	> 50 %	> 60 %		n	> 50 %	> 60 %	
alle Schläge	92	52 %	45 %	48 %	29	69 %	66 %	65 %
Schläge > 1,0 ha	60	52 %	45 %	51 %	20	80 %	75 %	69 %
Schläge > 1,5 ha	33	61 %	55 %	57 %	11	82 %	82 %	71 %
Schläge > 2,0 ha	22	59 %	55 %	60 %	7	86 %	86 %	73 %

Die flächenmäßige Klassifikationsgenauigkeit der pixelorientierten Methode (Tabelle 10) lag in Abhängigkeit der beobachteten Schlaggröße in RLP zwischen 46 % und 61 %, in BW deutlich höher zwischen 58 % und 72 %. Werden anstatt der klassifizierten Fläche die klassifizierten Schläge herangezogen, verändert sich die Genauigkeit, je nachdem, welche Mindest-Pixeldeckung für einen Schlag vorausgesetzt wird.

Analog konnten mit der objektorientierten Klassifikationsmethode (Tabelle 11) flächenmäßige Klassifikationsgenauigkeiten zwischen 48 % und 60 % in RLP und – wiederum höher – zwischen 65 % und 73 % in BW erzielt werden. In BW wurden noch höhere Klassifikationsgenauigkeiten (bis zu 86 %) dann registriert, wenn der Anteil der klassifizierten Schläge als Kriterium herangezogen wurde.

Aus Tabelle 10 und Tabelle 11 geht deutlich hervor, dass die Qualität der Klassifikation in beiden Regionen mit zunehmender Schlaggröße zunimmt. Der Anteil von Mischpixel, die in der Regel am Feldrand auftreten, nimmt mit zunehmender Schlaggröße ab, was dazu führt, dass im Verhältnis

mehr reine Pixel vorliegen. Damit entsteht eine höhere Klassifikationssicherheit, die Klassifikationsgüte erhöht sich. Sowohl der pixel- als auch der objektorientierte Ansatz erbrachten in BW die höhere Genauigkeit. Ursächlich könnte die Kulturreichhaltigkeit sein, die in BW weniger ausgeprägt ist (6 Hauptkulturen) als in RLP (9 Hauptkulturen), wodurch die Klassifikation vereinfacht wird (siehe Kapitel 2.2). Des Weiteren ist aufgrund des Realteilungsrechtes in RLP und der damit einhergehenden Zerstückelung der Flurstücke davon auszugehen, dass die Schlaggrößen tendenziell kleiner sind als in BW. Der *salt-and-pepper*-Effekt und die damit zusammenhängenden Fehlklassifikationen konnten durch die objektorientierte Software sichtlich eliminiert werden, obwohl dadurch auch eine Generalisierung einhergeht (siehe Abbildung 25 und Abbildung 26). Generell kann festgehalten werden, dass mit dem objektorientierten Ansatz für kleinere Schlaggrößen im Vergleich zur pixelbasierten Methodik bessere Ergebnisse erzielt wurden, während bei größeren Feldschlägen keine gravierenden Unterschiede festgestellt wurden.

Die Flächenerhebung seitens der Behörden (Landesstatistikämter) wird im Rahmen der Bodennutzungshaupterhebung durchgeführt und findet alle 4 Jahre statt. Im betreffenden Jahr wurde diese Erhebung nicht durchgeführt, womit ein Vergleich mit offiziell erhobenen Zahlen zur Flächennutzung nicht möglich war. Die durchgeführte Evaluierung wurde mit unabhängigen *Ground Truth* Daten durchgeführt, die für eine Überprüfung zurückgehalten wurden.

Da im vorliegenden Untersuchungsfall speziell die Genauigkeit der Aussageergebnisse bzgl. der Sommergerste von Interesse ist, ist die klassische Fehlermatrix hier weniger aussagekräftig. Die pixelbasierte Klassifikations-Fehlermatrix ließ sich aufgrund des dort angewandten Ausschließlichkeitsverfahrens ohnehin nicht berechnen. Die Fehlermatrizen der objektorientierten Klassifikation können dem Anhang entnommen werden (Tabelle A 7 und Tabelle A 8), die häufigsten Verwechslungsklassen waren Raps, andere Korngetreidearten und (Früh-)Kartoffel.

Arbeitstechnisch überwogen in dieser Untersuchung die Vorteile der objektorientierten Klassifikation. Diese Klassifikation wurde in einem Arbeitsschritt durchgeführt, sodass auch nur eine Evaluation nötig war. Dies führte zu erheblicher Zeiteinsparung; obwohl die genannte Vorgehensweise prinzipiell auch beim pixelbasierten Klassifikationsansatz möglich war, wurde sie aus Gründen der erwarteten verstärkten Fehlerkonfusion nicht angewandt. Die objektorientierte Software hat daneben den Vorteil, auch Form-, Texturparameter und Nachbarschaftsbeziehungen zwischen Objekten zu berücksichtigen, auch wenn dies konkret nur sehr bedingt eingesetzt werden konnte. Hinsichtlich der Nachvollziehbarkeit überzeugte die pixelbasierte Software. Sie ermöglichte die exakte und transparente Wiederholung der Arbeitsschritte, während sich bei dem objektorientierten Ansatz beispielsweise die Resultate der Segmentierung je nach zugrundeliegender Auflösung der Aufnahmen ändern. Beispielhafte Vergleiche zwischen pixel- und objektorientierter Klassifikation sind in Abbildung 23, Abbildung 24, Abbildung 25 und Abbildung 26 dargestellt.




Abbildung 23: Beispiel einer pixelbasierten Sommergerste-Klassifikation am Standort Epfendorf in der Untersuchungsregion BW. Tatsächliche sowie klassifizierte Sommergerste ist graphisch überlagert dargestellt.




Abbildung 24: Objektorientierte Klassifikation im Vergleich zur pixelbasierten Klassifikation in Abbildung 23.



Abbildung 25: Verkleinerte Darstellung der Abbildung 23 (pixelbasierte Klassifikation). Deutlich zu sehen ist der *salt-and-pepper*-Effekt im Umfeld des untersuchten Standortes.



Abbildung 26: Objektorientierte Klassifikation im Vergleich zur pixelbasierten Klassifikation in Abbildung 25. Der *salt-and-pepper*-Effekt konnte deutlich reduziert werden.

5.2 Ergebnisse der Ertragsprognosen

5.2.1 Einfaches Ertragsprognosemodell

Die Ergebnisse der Ertragskorrelationen des einfachen Ertragsprognosemodells sind für die kalenderbasierten NDVI-Akkumulationen in Tabelle 12 und für die GDD-basierten NDVI-Akkumulationen in Tabelle 13 angeführt. Eine grafische Darstellung der positiven und negativen Fehlerabweichungen wird in Abbildung 27 gezeigt, die einzelnen numerischen Werte aller durchgeführten Prognosen können der Tabelle A 15 im Anhang entnommen werden.

Das vordergründige Ziel war es, die Phasen zu finden, in denen akkumulierte NDVI-Summen am deutlichsten mit den Flächenerträgen von Sommergerste korrelierten.

Die bestkorrelierten Zusammenhänge wurden für die Akkumulation mittels GDD über den Zeitraum vom Ährenschieben bis zur Gelbreife erzielt (bezeichnet mit GDD2 – siehe Abbildung 17). Pflanzenphysiologisch gesehen entspricht dieser Zeitraum in etwa der Kornfüllungsphase. Mit diesem Ansatz wurden für alle Landkreise in beiden Regionen signifikante Korrelationen festgestellt. Dieses Modell zeigte über alle Landkreise den geringsten Standardfehler und die geringste mittlere Abweichung. Das analoge Bild stellen die durchgeführten Prognosen dar. Hierbei wurden für alle einzelne Jahre von 1995 - 2002 Prognosen berechnet, die sich aus dem abgeleiteten Modell der restlichen Daten dieser Zeit ergaben. Die Ergebnisse sind jeweils im rechten Teil der beiden Tabellen zu sehen und setzen sich aus 8 Prognosen je Landkreis zusammen. Die Periode GDD2 zeigte hier eine je Landkreis gemittelte Abweichung von prognostiziertem zu berichtetem Ertrag, die im ungünstigsten Fall bei 8,9 % lag. Der über alle Landkreise gemittelte Fehler der Akkumulationsperiode GDD2 liegt bei 7,0 %. Hierbei wurden die Beträge der Fehlerabweichungen gemittelt, sodass sich positive und negative Abweichungen nicht gegenseitig aufheben. Die Statistische Schiefe (*skewness*) weist darauf hin, dass es sich bei der genannten Periode um die stabilste Form der Prognose handelt, welche die geringsten Werte für Über- (positive Schiefe) oder Unterschätzung (negative Schiefe) über alle untersuchten Jahre aufweist.

Obwohl die Perioden GDD2 und GDD3 einen ähnlichen Zeitraum wie Kal3 abdeckten (siehe Abbildung 17), ergaben sich bei der Korrelation für Kal3 niedrigere Werte für den Korrelationskoeffizienten. Dies könnte darauf zurückzuführen sein, dass die Phänologie bei der Akkumulation über starre Kalenderzeiträume keine Berücksichtigung findet. Intra- und interannuelle Abfragen auf Basis von Kalendereinheiten berücksichtigen nicht die phänologische Entwicklung, die in den verschiedenen Landkreisen unterschiedlich verlaufen kann. Dadurch kann es vorkommen, dass unterschiedliche oder sich nicht deckende Pflanzenentwicklungsphasen

miteinander verrechnet werden, da identische Kalenderabschnitte der verschiedenen Jahre nicht zwingend identische phänologische Phasen der Sommergerste repräsentieren.

Weniger deutliche Korrelationen ergaben sich sowohl bei den Abfragen über sehr lange Zeiträume, sowie über sehr frühe als auch sehr späte Phasen. Obwohl die frühen Phasen für die Anwender der Prognosezwecke sehr hilfreich wären, wurden für den Akkumulationszeitraum GDD1 keine brauchbaren Korrelationen gefunden. Auch die leichte zeitliche Verschiebung der GDD2 hin zum angenommenen Maximum der photosynthetischen Aktivität (GDD3) brachte gegenüber GDD2 keine Verbesserung. Damit sollte ein Zeitgewinn für den Anwender erreicht werden, der eine frühere Prognose als zum Zeitpunkt der Gelbreife wünscht. Wie die Ergebnisse zeigen, hatten sich die Korrelationen jedoch fast durchwegs verschlechtert. Der Anwender hätte konkret zu entscheiden, welche Zugeständnisse an die Prognosegenauigkeit bei einem vorgezogenen Prognosezeitpunkt gemacht werden können. Als Akkumulationszeiträume mit geringen Prognosefehlern konnten GDD2, GDD3 und GDD4 identifiziert werden. Zu beachten ist hierbei jedoch, dass neben einem geringen Prognosefehler auch die notwendige statistische Stabilität vorhanden ist. Diese wird über den Korrelationskoeffizienten R ausgedrückt. Erst die Betrachtung beider Größen gibt Aufschluss über die Güte einer Prognose. Als weiterer Parameter zur Beurteilung der Prognosequalität kann die maximal aufgetretene Abweichung einer Reihe von Prognosen herangezogen werden, will man extreme Ausreißer von der Beurteilung ausschließen, ist dafür das 90-Perzentil geeignet.




Abbildung 27: Abweichungen der Prognosen von den offiziell berichteten Sommergersterträgen für die untersuchten NDVI-Akkumulationsperioden des einfachen und erweiterten Ertragsprognosemodells. Dargestellt sind die Abweichungen, die Mittelwerte und das 90%-il aller Prognosen der Jahre 1995 – 2002 aller Landkreise beider Untersuchungsregionen als absolute %-Beträge (vergl. auch Anhang, Tabelle A 15).

Tabelle 12: Modell- und Prognoseevaluation der NOAA-NDVI-Korrelationen mit Sommergerstenerträgen der Landkreise des Untersuchungsgebietes der Jahre 1995 - 2002 über Kalenderperioden (über Julianische Tage definiert).

NDVI-Akkumulationsperiode	Lkreis	Ergebnisse Modell		Ergebnisse Prognosen 1995 - 2002				
		R	Stdf. [t ha ⁻¹]	Mittl. Abw. [%]	Mittl. Abw. [t ha ⁻¹]	in [%]	als 90%-ile	Schiefe
Kal1 (10.4. - 17.7)	Germ	0,51	0,53	8,4	1,13	29,9	26,2	0,62
	Süw	0,75	0,37	5,3	0,62	13,3	10,8	0,28
	Fds	0,43	0,41	6,5	1,18	29,7	20,7	0,85
	Rott	0,51	0,48	7,4	1,46	36,9	22,8	1,04
	Tutt	0,85	0,29	4,5	-0,45	-11,5	-10,8	-0,03
	Zak	0,79	0,32	5,3	0,54	15,5	13,0	0,06
Mittelwert			0,40	6,2	9,4			0,47
Kal2 (Mai)	Germ	0,49	0,54	8,0	-1,14	30,3	19,3	1,18
	Süw	0,75	0,38	5,2	-0,66	14,2	11,1	0,34
	Fds	0,36	0,42	6,8	-0,93	23,3	18,6	0,53
	Rott	0,48	0,48	7,7	-1,37	34,4	23,2	0,93
	Tutt	0,82	0,31	4,4	0,61	-11,7	-9,9	-0,71
	Zak	0,76	0,33	5,4	-0,65	18,6	14,1	0,18
Mittelwert			0,41	6,2	8,8		0,41	
Kal3 (Juni)	Germ	0,53	0,52	8,7	1,46	-33,6	-29,7	-0,02
	Süw	0,60	0,45	6,5	0,88	-15,5	-14,8	-0,05
	Fds	0,43	0,41	6,8	-0,86	21,6	17,6	0,45
	Rott	0,53	0,47	7,6	-1,26	31,8	23,5	0,86
	Tutt	0,69	0,39	6,5	-0,56	14,3	13,6	-0,30
	Zak	0,85	0,28	4,3	-0,58	13,2	10,3	0,72
Mittelwert			0,42	6,7	9,9		0,20	
Kal4 (Juli)	Germ	0,05	0,62	10,2	-1,07	28,5	25,7	0,32
	Süw	0,15	0,56	8,5	1,51	-26,9	-24,5	-0,21
	Fds	0,06	0,45	7,8	-3,06	70,4	34,4	1,98
	Rott	0,84	0,30	4,9	0,63	-14,6	-13,5	0,25
	Tutt	0,86	0,27	4,5	0,85	-19,7	-15,2	-0,60
	Zak	0,75	0,34	6,2	-0,76	21,8	18,3	0,53
Mittelwert			0,42	7,0	11,1		0,38	

Tabelle 13: Modell- und Prognoseevaluation der NOAA-NDVI-Korrelationen mit Sommergerstenerträgen der Landkreise des Untersuchungsgebietes der Jahre 1995 - 2002 in Abhängigkeit der Phänologie (über GDD bestimmt).

NDVI-Akkumulationsperiode	Lkreis	Ergebnisse Modell		Ergebnisse Prognosen 1995 - 2002					
		R	Stdf. [t ha ⁻¹]	Mittl. Abw. [%]	Mittl. Abw. [%]	Max. Abw. [t ha ⁻¹]	in [%] als 90%-ile	Schiefe	
GDD1 SCH - ÄS	Germ	0,20	0,60	9,5	13,8	1,41	37,6	30,5	1,04
	Süw	0,19	0,55	8,1	11,4	0,85	19,6	19,4	0,25
	Fds	-0,01	0,45	7,6	11,9	1,19	27,5	20,4	0,66
	Rott	0,31	0,52	8,3	11,6	1,06	26,7	21,2	0,44
	Tutt	-0,36	0,50	7,8	9,7	1,00	25,5	16,5	1,19
	Zak	0,49	0,45	7,7	10,8	0,99	28,4	21,2	1,05
Mittelwert			0,51	8,2	11,5				0,77
GDD2 ÄS - GR	Germ	0,78	0,39	6,6	8,9	0,77	19,5	15,7	0,84
	Süw	0,74	0,38	5,5	7,6	0,88	16,9	13,1	0,27
	Fds	0,71	0,32	4,9	6,3	-0,54	-11,1	-10,6	-0,95
	Rott	0,78	0,35	5,0	8,4	-0,88	-22,3	-17,6	-0,18
	Tutt	0,92	0,20	2,9	3,7	0,38	7,8	7,3	-0,11
	Zak	0,85	0,27	4,9	7,3	0,63	18,0	15,8	0,47
Mittelwert			0,32	5,0	7,0				0,06
GDD3 Maximale photosynthet. Aktivität	Germ	0,48	0,54	8,6	11,5	1,11	28,2	23,8	1,18
	Süw	0,85	0,30	3,8	4,8	0,70	15,2	9,1	1,65
	Fds	0,48	0,39	6,4	9,1	0,78	19,5	17,8	0,56
	Rott	0,77	0,35	5,2	6,6	0,79	18,3	10,4	1,27
	Tutt	0,80	0,32	4,4	5,5	0,61	14,1	11,6	0,30
	Zak	0,73	0,35	6,1	8,8	0,72	20,6	16,2	0,37
Mittelwert			0,38	5,7	7,7				0,89
GDD4 SCH - GR	Germ	0,61	0,49	7,6	9,8	1,04	27,6	15,7	1,26
	Süw	0,60	0,45	6,7	9,2	0,86	16,5	13,1	0,20
	Fds	0,70	0,32	4,8	6,1	0,47	10,9	10,6	-0,54
	Rott	0,66	0,42	5,8	8,3	0,61	15,3	17,6	0,00
	Tutt	0,87	0,26	4,0	5,2	0,52	10,6	7,3	0,79
	Zak	0,88	0,24	4,0	5,8	0,53	15,2	15,8	0,90
Mittelwert			0,36	5,5	7,4				0,43

5.2.2 Erweitertes Ertragsprognosemodell

Die Berechnung des erweiterten Ertragsprognosemodells wurde für den NDVI-Akkumulationszeitraum GDD2 durchgeführt, da damit im einfachen Ertragsprognosemodell die besten Ergebnisse erzielt wurden. Ein Vergleich der Modell- und Prognoseevaluation des erweiterten Ertragsprognosemodells (Tabelle 14) mit den Ergebnissen des einfachen Ertragsprognosemodells in Tabelle 13 zeigt für das erweiterte Modell generell eine leichte Verbesserung der Ergebnisse. Dies schlägt sich in den verbesserten Korrelationskoeffizienten des Modells nieder. Leichte Verbesserungen sowie in einigen Fällen Verschlechterungen zeigen sich in der Prognoseevaluation, die über alle jeweiligen Jahre zwischen 1995 und 2002 durchgeführt wurde. Der Mittelwert der Abweichungen konnte von 7,0 % auf 6,4 % verbessert werden. Dass die Verbesserung nicht deutlicher ausgefallen ist, liegt auch an einem Ausreißer, wie die Abbildung 27 zeigt. Die maximalen Abweichungen sind teils gesunken und teils gestiegen. Die Schiefe, womit die systematische Unter- oder Überschätzung ausgedrückt werden soll, hat sich tendenziell kaum verändert, womit sich Unter- und Überschätzungen die Waage halten.

Tabelle 14: Modell- und Prognoseevaluation der Jahre 1995 – 2002 des um Stressfaktoren erweiterten Sommergerste-Ertragsprognosemodells für die NDVI-Akkumulationsperiode GDD2 (ÄS - GR).

NDVI-Akkumulationsperiode	Lkreis	Ergebnisse Modell		Ergebnisse Prognosen 1995 - 2002					
		R	Stdf. [t ha ⁻¹]	Mittl. Abw. [%]	Mittl. Abw. [t ha ⁻¹]	Max. Abw [t ha ⁻¹]	in [%]	als 90%-ile	Schiefe
GDD2	Süw	0,75	0,37	5,0	7,0	0,76	14,63	13,80	-0,06
	Fds	0,75	0,30	4,8	6,2	-0,60	-12,32	-9,50	-1,35
	Rott	0,80	0,33	5,4	8,7	-0,95	-23,99	-17,70	0,13
SCH - ÄS	Tutt	0,92	0,21	2,9	3,7	0,38	7,77	7,40	-0,16
	Mittelwert		0,30	4,5	6,4				-0,36




Abbildung 28: Restdifferenz zwischen modelliertem Ertrag (erweitertes Ertragsprognosemodell) und berichtetem Ertrag (Quellen: Stat. Landesämter) für 4 Landkreise über einen Zeitraum von 8 Jahren.

Die Abbildung 28 zeigt die verbleibende Restdifferenz zwischen modelliertem (erweitertes Ertragsprognosemodell) und berichtetem Ertrag, der in 29 von 32 Fällen im Bereich von $\pm 3,5$ dt liegt und in nur 3 Fällen darüber hinaus liegt. Es ist keine deutliche Asymmetrie der Schätzung, etwa durch eine verstärkte Über- (positive Differenzen) oder Unterschätzung (negative Differenzen) festzustellen. Die Restdifferenz verteilt sich in beiden Bereichen gleichmäßig.

Offen bleibt, in welchem Ausmaß eine nachträgliche Korrektur der Erntevorhersage, welche sich auf Wirkungsfaktoren stützt (wie z. B. dem NDVI), mit Hilfe von Ursachefaktoren (wie z. B. agrarmeteorologischen Größen) möglich ist, da deren Wirkung unter Umständen in zweifacher Hinsicht zu berücksichtigen ist. So ist die Jahreswitterung ohne Zweifel maßgeblich für die Veränderung der NDVI-Werte der Vegetation ausschlaggebend. Zugleich können Einzelfaktoren der Witterung (z. B. die Temperatur) eine unmittelbare Wirkung auf den Ertrag der Pflanze haben, die sich nicht im NDVI erkennen lässt. Das heißt, aufgrund des empirisch-statistischen Modellansatzes ist die Differenzierung, in welchem Ausmaß Phänomene, die einen Ertragsrückgang zur Folge haben, bereits in den NDVI-Aufnahmen erfasst sind und in welchem Ausmaß sie zusätzlich über die Ursachefaktoren korrigiert werden könnten, kaum möglich. Der vorliegende Fall

lässt darauf keine abschließende Antwort zu. Die mittels mathematischem Verfahren (*Simplex*-Methode - MODELKINETIX, 2000; NELDER & MEAD, 1965) optimierten Parameter zeigten zwischen einzelnen Landkreisen kein einheitliches Verhalten in der Optimierung des Korrekturausmaßes. Es zeigte sich jedoch, dass die Korrekturen in den meisten Fällen nur zu einer geringfügigen Verbesserung der Schätzergebnisse führten. Demzufolge werden in den durchgeführten Untersuchungen die Effekte der Ursachefaktoren in den genutzten FE-Daten (Wirkungsfaktoren) so präzise erfasst, dass eine weitere Korrektur, sofern überhaupt, nur in einem geringen Ausmaß nötig ist. Darauf weisen in gewisser Weise auch die Ergebnisse der Optimierung hin (Tabelle 9). Der Dimensionierungsfaktor für Stress, der theoretisch zwischen 0 und 1 liegen kann, wurde auch nach der Optimierung nie voll ausgenutzt, sondern belief sich im Durchschnitt auf 0,1.

Bei NOAA-AVHRR-NDVI-Maximalwertkompositen mit ihrer hohen und regelmäßigen zeitlichen Frequenz ist im Gegensatz zu unregelmäßig verfügbaren hochauflösenden FE-Aufnahmen durchaus davon auszugehen, dass weitere Korrekturen nur bedingt Verbesserungen erbringen können, da der Großteil der am Boden stattfindenden relevanten Prozesse und Effekte implizit in den Aufnahmen abgebildet wird.

Starke Verbesserungen der Prognosen mit konventionellen Daten im Sinne von Stressfaktoren sind ausgeblieben. Die geringfügigen Verbesserungen, die im erweiterten Modell erreicht wurden, dürfen nicht so verstanden werden, dass konventionelle Daten für eine Verbesserung der Modellierung nicht notwendig seien. Dies ergibt sich schon daraus, dass durch die Verwendung phänologischer und meteorologischer Daten zur Ableitung der Temperatursummen (*Growing Degree Days*) deutlich bessere Prognoseergebnisse erzielt wurden als mit auf Kalenderperioden gestützten Prognosen.

Aus wirtschaftlicher Sicht stehen im vorliegenden Untersuchungsfall die mittels Stressfaktoren erreichten Verbesserungen der Modellierung bzw. der Prognose in keinem ökonomischen Verhältnis zu dem damit einhergehenden Aufwand für die Prozessierung und den anfallenden Kosten. Das bestehende Verbesserungspotential gründet sich somit vor allem auf einheitlich verfügbare und qualitativ hochwertige Daten (z. B. Bodendaten, Evapotranspirationsdaten).

Die agrarstatistisch berichteten Erträge schwanken zwar in den Jahren beträchtlich (die durchschnittliche Standardabweichung der Ernteerträge von 1995 - 2002 beträgt 5 dt ha^{-1} bei einem durchschnittlichen Sommergerstenertrag von 47 dt ha^{-1}), gleichzeitig lassen die Erträge jedoch auch erkennen, dass die untersuchten Jahre keine extremen Katastrophenjahre waren. Unter der Annahme, dass Extremsituationen dieser Art über Korrelationen aufgrund mangelnder Elastizität nicht ausreichend gut prognostiziert werden können, könnten Stressfaktoren die notwendige Ergänzung bieten. Eine diesbezügliche Evaluation war jedoch nicht möglich.

5.2.3 Sensitivitätsanalyse

Zur Feststellung der Auswirkungen durch Änderung eines Parameters auf das Modell, wurde eine Sensitivitätsanalyse durchgeführt. Getestet wurde die Wirkung des jeweiligen Modellparameters „Anteil an der Korrektur“ (Dimensionierungsfaktor), welcher indirekt auch die Größe des Quantifizierungsfaktors der Stressauswirkung bestimmt und damit essentiellen Einfluss auf die Modellergebnisse hat. Der Parameter konnte theoretisch zwischen 0 und 1 liegen. Die Ergebnisse sind für den Landkreis Freudenstadt (FDS) stellvertretend in Abbildung 29 graphisch dargestellt.

Die Sensitivitätsanalyse der 5 durchgeführten Korrekturen zeigt die Empfindlichkeit der Auswirkung eines Parameters auf die Änderung des Ertrages. Diese Änderung kann positiv oder negativ ausfallen, im Falle der Trockenstresskorrektur (über CWSI) sind nur Abwertungen des über NOAA-AVHRR-NDVI prognostizierten Ertrages möglich (Abbildung 29 c und e), da bei optimalen Wasserverhältnissen ($CWSI = 0$) davon ausgegangen wird, dass es zu keiner Reduktion aber auch zu keiner Aufwertung des Ertrages kommt. Die Sensitivitätsanalyse ist für jeden der 5 Parameter für denselben Schwankungsbereich dargestellt und reicht in der (beispielhaften) graphischen Darstellung von 2,5 - 25 %. Die optimierten Parameter in Tabelle 9 zeigen jedoch, dass auch höhere Werte möglich sind. Die Korrekturen liegen allerdings auch bei den genannten höheren Werten bei maximal $1,7 \text{ dt ha}^{-1}$ und somit in einem durchaus plausiblen Bereich.

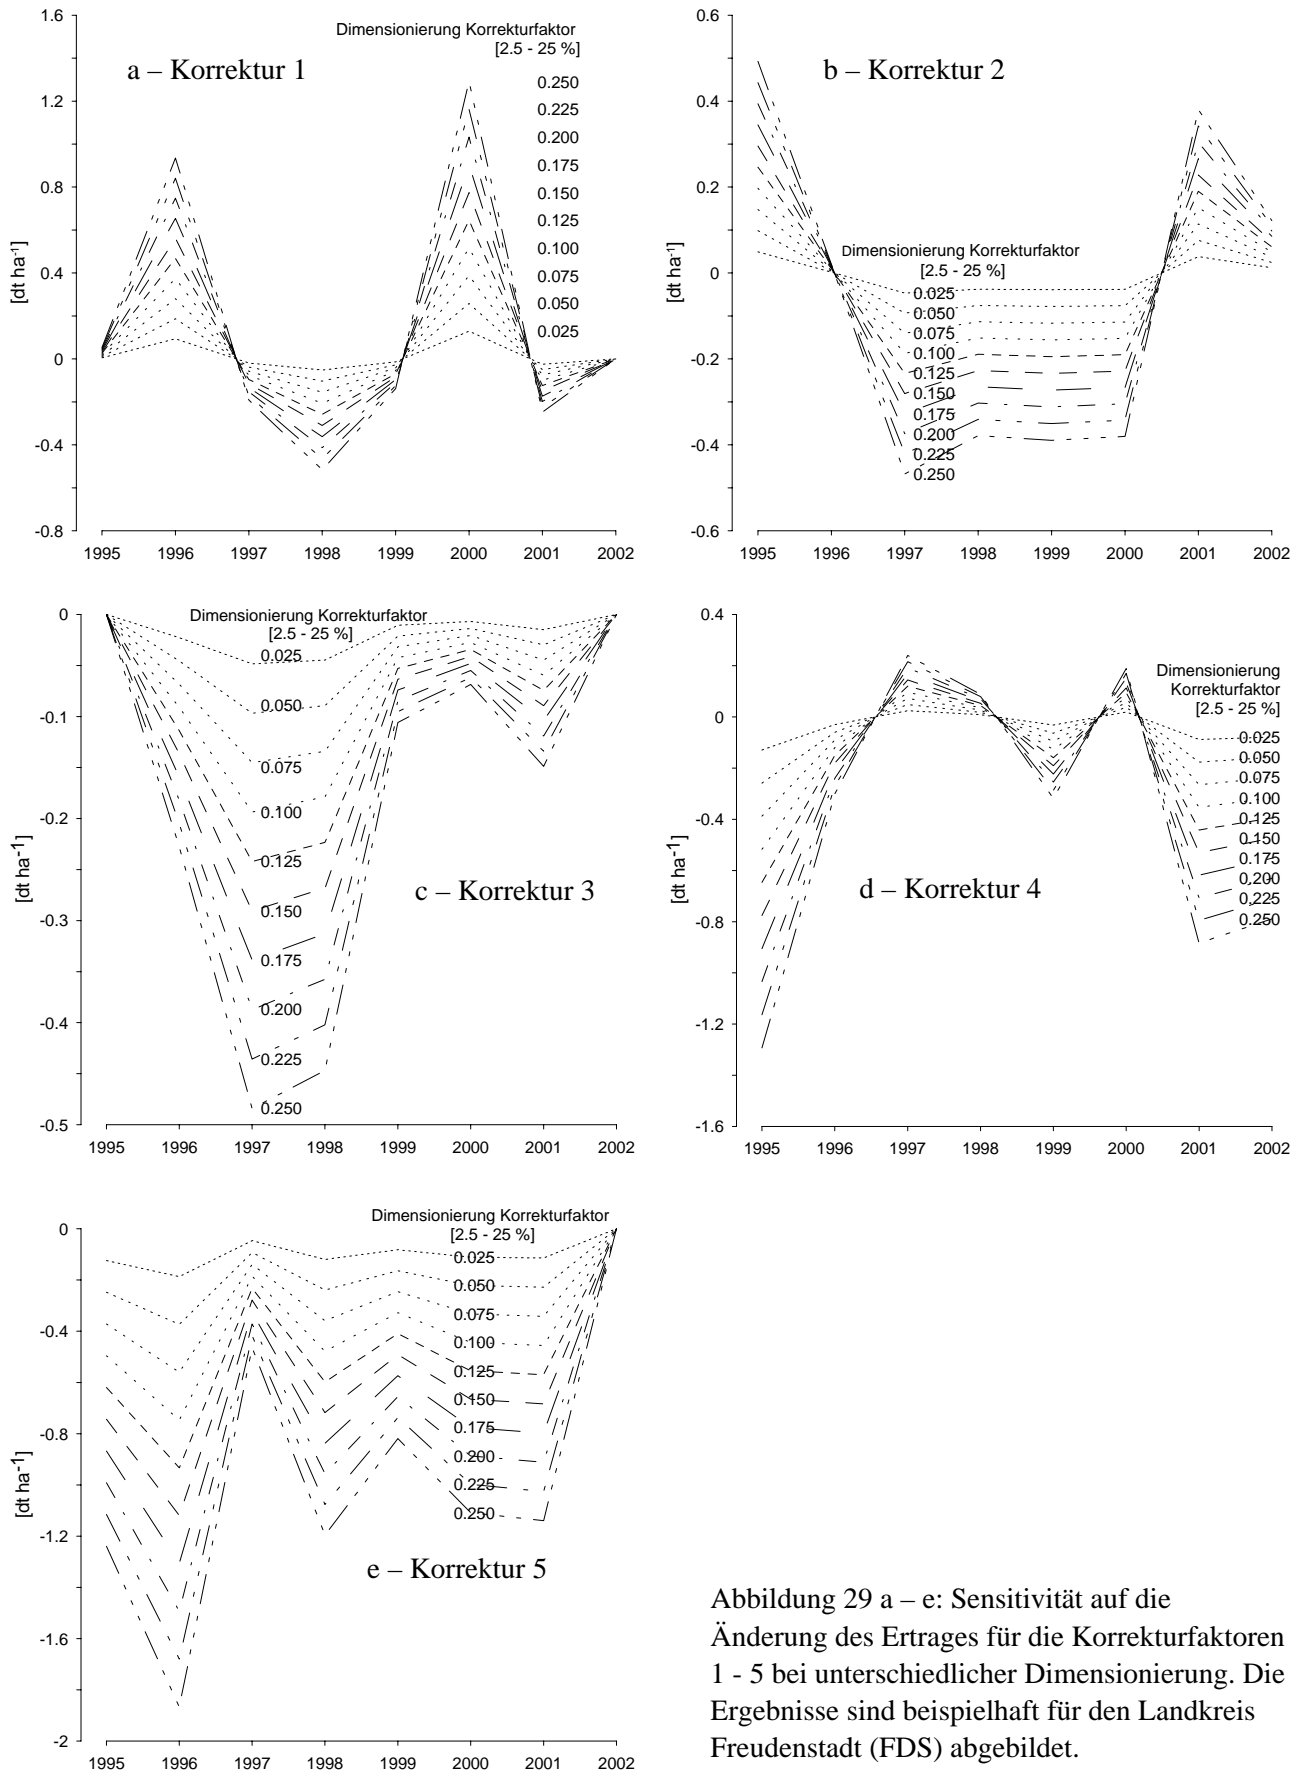


Abbildung 29 a – e: Sensitivität auf die Änderung des Ertrages für die Korrekturfaktoren 1 - 5 bei unterschiedlicher Dimensionierung. Die Ergebnisse sind beispielhaft für den Landkreis Freudenstadt (FDS) abgebildet.




Abbildung 30: Jährliche, aus 5 Korrekturen (Stressfaktoren) summierte Auf- und Abwertungen der aus NOAA-AVHRR-NDVI-MVC prognostizierten Sommergerstenerträge für 4 Landkreise.

Die für die 5 Parameter vorgenommenen Auf- bzw. Abwertungen werden schließlich addiert und können sich somit auch gegenseitig aufheben. Diese verrechneten Auf- und Abwertungen sind in Abbildung 30 dargestellt und zeigen für den untersuchten Zeitraum Gesamtkorrekturen von 0 bis zu 2 dt. Deutlich erkennbar sind die für jeden Landkreis unterschiedlichen Korrekturen.

6 Stellungnahme

In der Literatur sind nur wenige Untersuchungen bekannt, die sich mit der Klassifikation einer bestimmten Getreideart neben mehreren anderen auseinandersetzen (siehe Kapitel 2.2). Der Großteil der in der Literatur berichteten Klassifikationen stützt sich – im Vergleich zu diesen – auf weitaus günstigere Bedingungen, soweit sie die Gegebenheiten der Untersuchungsregion betreffen bzw. klassifiziert in größeren Klassen, womit die Ergebnisse nur bedingt vergleichbar sind.

Multitemporale **Klassifikationen** sowie die Integration von wissensbasierten Regeln haben sich in der vorliegenden Studie zur Identifikation von Sommergerste als geeignet erwiesen. Die Verwendung von NDVI-Schwellenwerten zur Unterscheidung von Getreidearten wird auch von anderen Autoren empfohlen (TOULIOS & TOURNAVITI, 2003). Die Klassifikation greift auf erhobene *Ground Truth* Daten zurück, die v. a. für die Definition der wissensbasierten Regeln hilfreich waren und so auch von anderen Autoren eingesetzt wurden (COHEN & SHOSHANY, 2002). Eine Klassifikation ohne *Ground Truth* Daten erscheint nur erschwert möglich. Die alternativ dafür notwendige Datenbank, bestehend aus historischen Felduntersuchungen, müsste umfangreich sein und die Phänologie der landwirtschaftlichen Hauptkulturen umfassen. Dabei müssten auch regionalspezifische Eigenheiten (z. B. Höhenlage), die sich auf die Phänologie auswirken, einfließen.

Die Klassifikation wurde parallel mit einem objektorientierten und pixelorientierten Ansatz durchgeführt. Während beim pixelorientierten Verfahren jeder einzelne Bildpunkt berücksichtigt wird, werden beim objektorientierten Verfahren zunächst durch Segmentierung Objekte gebildet, die anschließend klassifiziert werden. Dies führt dazu, dass pixelorientierte Klassifikationen deutlich inhomogener vorliegen. Das Phänomen des Verschwindens einzelner, *in natura* jedoch vorliegender Pixel und das vereinzelte, ungruppierte Auftreten der Pixel andererseits wird im Fachjargon als *salt-and-pepper-Effekt* bezeichnet. Im vorliegenden Fall waren die Einzelpixel häufig falsch klassifiziert. Über Filter konnte dieses Problem nur begrenzt behoben werden. Objektorientierte Verfahren unterdrücken dieses Problem, da sich die Klassifizierung von vorneherein auf Objekte (*Cluster*) erstreckt. Damit geht allerdings auch eine Generalisierung einher. Deshalb kommt es u. a. auf die Auswahl der richtigen Größe der zu bildenden Segmente an. Hier wurden die besten Erfahrungen dann gemacht, wenn zu klassifizierende Schläge aus durchschnittlich 1 – 5 Segmenten bestanden. Die Literatur kann hinsichtlich eines geeigneten Skalierungsparameters (*scale parameter*) keine eindeutigen Empfehlungen abgeben (DARWISH et al., 2003). Um keine Schläge durch Generalisierung zu „verlieren“, sollte die Segmentgröße nicht kleiner gewählt werden als der kleinste zu klassifizierende Schlag. Die Segmentierung in der objektorientierten Software wurde in erster Linie dafür entwickelt, um FE-Daten mit viel Texturinformation zu verarbeiten, die typischerweise bei Radardaten oder sehr hoch auflösenden Aufnahmen auftritt (BAATZ et al., 2001). Vor allem in Räumen mit hoher „Bildunruhe“ und räumlicher Komplexität sind mit sehr hoch auflösenden FE-Daten Verbesserungen gegenüber

pixelbasierter Klassifikation möglich (BLASCHKE & STROBL J., 2001; GUANAES REGO & KOCH, 2003). Bei den hier verwendeten LANDSAT-Aufnahmen landwirtschaftlicher Flächen ist dagegen von deutlich weniger Texturinformation innerhalb der Schläge auszugehen. Die Schwäche des objektorientierten Ansatzes liegt vor allem in der Segmentierung, welche die Übertragbarkeit und die Standardisierung des Verfahrens einschränkt, da Kriterien zur Festlegung der Segmente immer iterativ durch den Benutzer erfolgen (KOCH et al., 2003; KOCH & IVITS, 2002).

Je nach angewandter Klassifikationsmethode konnten zwischen 46 % und 73 % der Sommergerstenfläche klassifiziert werden. Mit diesen Ergebnissen lagen die Ergebnisse im Bereich von zwei ähnlichen in der Literatur bekannten Untersuchungen, bei denen Klassifikationsgenauigkeiten für Sommergerste von 66 % (MLR, 1995) sowie von 40 % und 65 % (HALL-KÖNIVES, 1990) erzielt wurden. Obwohl grundsätzlich höhere Genauigkeiten für eine verbindliche quantitative Aussage gewünscht werden, können vergleichende qualitative Aussagen zur Entwicklung der Sommergerstenanbauflächen getroffen werden. Für den Nutzer, der hinsichtlich des Anbauumfangs über Vorwissen verfügt, stellen diese Daten wertvolle Informationen dar.

Die Klassifikationsergebnisse des objektorientierten Ansatzes erbrachten im Vergleich zum pixelorientierten Ansatz hinsichtlich der kleineren Schläge leichte Verbesserungen. Die Evaluierung beider Verfahren erfolgte aufgrund zurückgehaltener unabhängiger *Ground Truth* Daten. Eine ergänzende Bewertung der Klassifikationsergebnisse ist grundsätzlich über das offiziell berichtete Flächenausmaß des Sommergerstenanbaus möglich. Da die entsprechenden Zahlen nur alle 4 Jahre erhoben werden und für 2001 nicht zur Verfügung standen, konnte dieser Abgleich nicht vorgenommen werden.

Die objektorientierte Software erlaubte die Definition von Form- und Texturparametern sowie von Nachbarschaftsbeziehungen zwischen Objekten. Dies ist vor allem im Hinblick auf sehr hochauflösenden Daten hilfreich, aufgrund der vergleichsweise mäßigen räumlichen Auflösung konnten im vorliegenden Untersuchungsfall nur bedingt Formparameter eingesetzt werden. *Fuzzy*-Techniken (unscharfe Abgrenzungen), die vielfach erfolgreich eingesetzt wurden (FOCKELMANN, 2002; STANKIEWICZ et al., 2003) kamen überwiegend mit der objektorientierten Software, aber auch mit der pixelorientierten Software zum Einsatz.

Es hat sich bewährt, mit nur einem Fernerkundungssensor zu arbeiten, womit Kompatibilitätsprobleme von vorneherein vermieden wurden. Die strukturellen Gegebenheiten der Untersuchungsregionen zeigten sich für die Klassifikation mit LANDSAT-Aufnahmen als nicht ideal. Wie die Ergebnisse zeigen, waren Mindestschlaggrößen von 2 ha erforderlich, um 60 bis 73 % der Sommergerstenfläche richtig zu klassifizieren. Zu denken wäre auch an den Einsatz

räumlich höher auflösender Satellitenaufnahmen. Bei der derzeitigen Preislage ist dies allerdings für den operationellen Einsatz nur eingeschränkt möglich.

Klassifiziert wurde Sommergerste. Der Anteil an braufähiger Ware kann über Schätz- oder Erfahrungswerte bestimmt werden. In der objektorientierten Klassifikation fanden auch andere landwirtschaftliche Kulturen, zwar nicht aus primären Zwecken, aber als sekundäre Nebeneffekte, Berücksichtigung. Da Verwechslungen zwischen Konkurrenzkulturen nicht dezidiert weiterverfolgt wurden, ist die erhaltene Statistik nur für Sommergerste aussagekräftig. Als häufige Verwechslungskulturen von Sommergerste wurden Getreidearten, Raps und (Früh-)Kartoffel registriert. Generell ist festzustellen, dass ein weniger artenreiches Kulturenmuster, wie es in Baden-Württemberg vorlag, zu einer Verbesserung der Klassifikationsergebnisse führte. Dass die Klassifikation von Landbedeckungen und -nutzungen stark variierender Zusammensetzung erschwert wird, wird auch in der Literatur belegt (KÜHBAUCH et al., 1990; SHACKELFORD & DAVIS, 2003).

Die Klassifikation basiert auf multitemporalen Satellitendaten, wobei der Aufnahmezeitpunkt der spätesten Aufnahme der 30.7.01 war. Eine Klassifikation zu einem um 2 - 3 Wochen früheren Zeitpunkt erscheint auch ohne Qualitätseinbußen möglich, eine deutlich frühere Klassifikation (> 1 Monat) dürfte für die Abgrenzung bestimmter Kulturen (z. B. Hafer) problematisch werden. Wie auch bei JEWELL (1989) berichtet, wurde in vielen Fällen der niedrige NDVI in der Abreife ausgenutzt, um Sommergerste von den noch vitalen Fruchtarten unterscheiden zu können.

Hinsichtlich der **Ertragsprognosemodellierung** (Flächenertrag) kann folgendes festgehalten werden:

Das Ziel, ein umsetzbares und operationell einsetzbares Prognosemodell zu entwickeln, wurde erreicht. Mit diesem Prognosemodell liegt ein prototypisches Modell vor, das mit vergleichsweise geringem Aufwand in einem operationellen System umgesetzt werden kann. Der Prognosefehler lag im Durchschnitt bei 7 % und 6,4 % für das einfache bzw. erweiterte Ertragsprognosemodell. Die Genauigkeiten fielen damit im Vergleich zu anderen Studien teilweise ähnlich, aber auch deutlich besser aus. Zu beachten ist jedoch, dass sich andere Untersuchungen häufig auf Weizen oder Getreide beschränkten sowie deren Randbedingungen günstiger waren: So wurde bei BOCHENEK (2000) ein durchschnittlicher Prognosefehler von 7,5 % für die „Sammelkultur Getreide“ erzielt, wobei der Getreideflächenanteil bei über 60 % lag. GENOVESE (2001) erzielte für Weizen einen durchschnittlichen Prognosefehler von 13,7 %, wobei die untersuchten Regionen großräumiger waren (NUTS-2-Ebene) und einer Vorauswahl nach Getreideflächenanteil am Ackerland unterzogen wurden.

Das Prognosemodell liefert Vorhersagen für den Flächenertrag von Sommergerste. Qualitätsparameter werden nicht prognostiziert. Lineare Zusammenhänge zwischen Quantität und Qualität sind nachgewiesen (SCHELLING et al., 2003a), womit eine weitreichendere Interpretation von Flächenerträgen möglich ist.

Das eingesetzte Modell basiert auf einem empirisch-statistischen Ansatz. Damit verbunden ist der Vorteil, großflächig und trotzdem regional differenzierte Prognosen zu ermöglichen. Adaptionen an verschiedene Regionen sind mit Änderungen verbunden, die jedoch relativ einfach durchzuführen sind. Die Anpassung auf weitere Kulturen (z. B. Weizen) ist möglich, zumal dieser Modelltyp damit bereits erprobt ist (BOCHENEK, 2000).

Kritisch anzumerken ist, dass die Amplitude der Prognosen, und damit ihre Elastizität, in einem gewissem Umfang von vergangenen Ernteschwankungen abhängig ist. Deshalb ist auf eine ausreichende Anzahl an Untersuchungsjahren zu achten. Der Lernprozess stützt sich auf die statistische Beziehung zwischen dem Ertrag der Sommergerste und der spektralen Reflexion der gesamten Vegetation auf Ackerflächen während des Wachstums oder zu bestimmten phänologischen Abschnitten des Wachstums. Auf die mit dem Wachstum bzw. dem Jahresablauf veränderten FE-Daten wurden die phänologischen Abschnitte der Sommergerste projiziert. Im vorliegenden Fall wurde diese Beziehung zwischen der Rot- bzw. Infrarot-Reflexion der Vegetation und den Sommergersteerträgen über eine Zeitspanne von 8 Jahren beobachtet. Gemäß SCHELLING (2000) ist für multiple Regressionen von konventionellen Daten eine Zeitreihe von 10 - 15 Jahren ideal. Für einfache lineare Korrelationen wurden jedoch auch schon kürzere Zeitreihen untersucht. Dies ist möglich, da man bei einfachen Korrelationen weniger dem Zwang der notwendigen Freiheitsgrade unterliegt. Für das vorliegende Modell erweitert sich mit jedem fortschreitenden Jahr die verfügbare Datenbasis, was eine Neuberechnung zur Folge hat. Eine kontinuierlich fortgesetzte NOAA-AVHRR Datenreihe gewährt damit die Fortführung und Verbesserung des aktuellen Modells.

Das Prinzip dieses Ertragsprognosemodells beruht also auf den Zusammenhang zwischen der Vitalität der beobachteten Vegetation und den Flächenerträgen. Die beobachtete Vegetation wurde auf ackerbauliche Flächen (*CORINE „non irrigated arable land“*) reduziert und bestand überwiegend aus Korngetreide. Einen ähnlicher Ansatz wurde bei GENOVESE et al. (2001) und COLEMAN (1995) verwendet. Aufgrund der Ähnlichkeit phänologischer Eigenschaften dieser Kulturen können die aus Fernerkundungsaufnahmen gewonnenen Informationen Aussagen zum Ertragspotential von Sommergerste liefern, obwohl der ackerbauliche Anteil von Sommergerste durchschnittlich bei knapp 20 % liegt. Die relativ guten Prognoseergebnisse sollen jedoch nicht darüber hinwegtäuschen, dass es sich bei den NOAA-AVHRR Aufnahmen bei einer Auflösung von 1,1 km um das Mischsignal unterschiedlicher Landnutzungen bzw. unterschiedlicher landwirtschaftlicher Kulturen handelt. Dennoch können diese Mischsignale den notwendigen

Informationsbedarf über die Vitalität der Vegetation liefern, wie der Fall der untersuchten Sommergerste zeigt. Auch andere Autoren haben Verfahren, die auf diesem Prinzip beruhen, erfolgreich eingesetzt (BOCHENEK, 2000; COLEMAN, 1995; GENOVESE et al., 2001; ILLERA et al., 2000)

Höher auflösende Daten wie LANDSAT wurden für die Prognose der Flächenerträge nicht eingesetzt. Ertragsprognosemodelle, die mit diesen Daten arbeiten, kommen zwar häufig mit wenigen Satellitenaufnahmen aus, benötigen aber als Eingabewerte in der Regel LAI oder APAR (MAAS, 1988b; MAAS, 1992; WIEGAND et al., 1986; WIEGAND & RICHARDSON, 1984). Diese Daten standen in dieser Untersuchung nicht zur Verfügung. Diese Modelle basieren normalerweise auf einem deterministischen Ansatz. Dabei ist generell eine größere Anzahl der Eingabewerte erforderlich, womit eine beabsichtigte Operationalisierung häufig nicht mehr realisierbar ist.

Die für die Ertragsprognose eingesetzten NOAA-AVHRR-NDVI-Maximalwertkompositen stehen kostenlos zur Verfügung, sodass ein großer Kostenfaktor entfällt. Die Qualität der Daten kann optimiert werden; eine Atmosphärenkorrektur bzw. BRDF-Korrektur kann die Aussagekraft der Aufnahmen weiter verbessern.

Die zeitliche Kontinuität (Historie), die niedrigen Kosten, die große räumliche Abdeckung und die hohe Wiederkehrtrate sind die Stärken von NOAA-AVHRR. Mit der hohen zeitlichen Auflösung ist es möglich, das Problem mit der Wolkenbedeckung über die Bildung von Kompositen zu umgehen, und dabei gleichzeitig die notwendige Datendichte beizubehalten. Dem Nachteil der groben räumlichen Auflösung kann unter Anwendung eines regionalen und empirisch-statistischen Prognosemodells abgeholfen werden. Auch bezüglich dieses Aspektes scheinen zukünftige Verbesserungen durch lange Zeitreihen anderer Sensoren möglich (SPOT-VEGETATION, TERRA-MODIS, ENVISAT-MERIS).

Besonderes Interesse bei der hier verwirklichten Lösung galt der Realisierbarkeit und der Umsetzbarkeit. Um dieses Ziel zu erreichen, wurden auch insofern vereinfachte Ansätze verfolgt, als damit keine deutlichen Minderungen der Prognosequalität zu erwarten waren. Trotzdem ist es gelungen, Ergebnisse von durchschnittlich 6,4 bzw. 7,0 % Fehlerabweichung zu erzielen, die im Vergleich zu den Untersuchungen in der Literatur (siehe oben sowie Kapitel 2.3.1) sehr gut liegen. Gerade für regionale Zwecke scheint das empirisch-statistische Modell mit den damit vorhandenen Möglichkeiten der Vereinfachung der geeignete Ansatz zu sein. Es muss bedacht werden, dass bei dieser Methode die Kulturmaßnahmen nicht explizit berücksichtigt werden. Es konnte jedoch davon ausgegangen werden, dass das landläufige Bewirtschaftungssystem ausreichend homogen ausgerichtet ist und das abbildende FE-System ausreicht, um diese Effekte hinreichend in das Prognosemodell einfließen zu lassen. Für die Industrie, die letztlich ihre Wirtschafts- und

Einkaufspolitik danach zu richten hat, dürften die erzielten Genauigkeiten dieses Verfahrens vollends ausreichen. Das entwickelte Modell kann also sowohl ergebnisorientiert als auch unter ökonomischen Gesichtspunkten überzeugen.

Die NDVI-Summen gehen als „Pseudointegral“ mit Tagesintervallen in das Prognosemodell ein. Damit ist gewährleistet, dass sowohl die Zeitdauer, über die der NDVI gemessen wird, als auch die Intensität des NDVI berücksichtigt wird. Dies ist aus pflanzenbaulicher Sicht von enormer Wichtigkeit. In der Ertragsbildung von Getreide ist die Dauer der Kornfüllungsphase maßgeblich (EVANS et al., 1978). Daraus ist zu schließen, dass besonders dann hohe Erträge erzielt werden, wenn der NDVI in der Kornfüllungsphase möglichst lange auf einem hohem Niveau bleibt, bevor er absinkt (KÜHBAUCH et al., 1991).

Eine deutliche Verbesserung der Prognosen ist mit der Projektion der phänologischen Phasen auf die AVHRR-NDVI-Werte mit der Verwendung von *Growing Degree Days* erzielt worden. Dadurch konnten die phänologischen Phasen ohne subjektive Berichterstattung reproduziert werden. Auch wenn die Pflanzenentwicklung nicht allein über den Temperaturverlauf bzw. über Temperatursummen beschrieben werden kann, zeigt dieser Ansatz einen praktikablen Weg, um wichtige phänologische Abschnitte von Kulturpflanzen im Jahresablauf zu identifizieren. Auch für die großräumige Anwendung, bei der mit einem höheren Heterogenitätsgrad hinsichtlich Phänologie zu rechnen ist, können, wie BOCHENEK (2000) zeigt, vorab agrarklimatisch unterscheidbare Regionen im Rahmen einer Stratifizierung differenziert werden.

Eine Weiterentwicklung des Prognosemodells hängt auch von der Datengrundlage ab. Hier dürften sich in Zukunft Verbesserungen der Datenlage ergeben. So wird derzeit die verwendete Landbedeckungskarte *CORINE land cover* aktualisiert und optimiert (KEIL et al., 2002). Des Weiteren ist neben einer verbesserten räumlichen Auflösung der hier eingesetzten Fernerkundungsdaten der Einsatz von linearen Entmischungsmethoden (*spectral linear unmixing*) denkbar, um auf die tatsächlichen spektralen Reflexionen im Subpixelbereich schließen zu können (FAIVRE & FISCHER, 2002; FISCHER, 1994). Für den großflächigen nationalen und europäischen Einsatz wäre eine einheitliche Datengrundlage von konventionellen Daten ebenso wünschenswert. Die benötigten Daten standen häufig nicht in der notwendigen Qualität zur Verfügung. So mussten Bodendaten ungleicher Qualität aus unterschiedlichen Datenquellen zusammengetragen werden: Hier ist noch ein Manko an Einheitlichkeit hinsichtlich Format, Kompatibilität und Auflösung zu verzeichnen.

Das hier erstellte Ertragsprognosemodell erlaubt die Schätzung des Ernteaufkommen 3 - 6 Wochen vor der Ernte. Durch die Prognose meteorologischer Faktoren und deren Wirkung könnte noch Zeit gewonnen werden, indem die spätesten NDVI-Werte nicht gemessen, sondern im Rahmen einer

NDVI-Prognose vorhergesagt werden. Die Ernteprognose wäre dadurch zwar mit Unsicherheiten verbunden, aber zeitlich früher verfügbar.

Die Ertragsprognose verläuft EDV-gestützt und damit wiederholbar. Für eine solche Ernteprognose spricht, dass sie dabei nicht menschlich subjektiven Einschätzungen hinsichtlich der Perzeption und Kognition unterliegt. Der Großteil der bisher zugänglichen Informationsdienste zum Ernteaufkommen greift bisher auf die „konventionelle“ Berichterstattung (z. B. Agrarhandel, Saatguthandel) zurück, eine Datenquelle, die ein unbekanntes Maß an Subjektivität beinhaltet. Für die Industrie ist es essentiell, objektive Informationen zu erhalten, da Fehlinformationen am Markt durchaus auch bewusst gestreut werden können (GRAMLICH, 2003).

In der vorliegenden Arbeit wurde das Ertragsprognosemodell in einer erweiterten Version so modifiziert, dass dadurch die Ableitung von Stressfaktoren für Trocken- und Temperaturstress basierend auf konventionellen bodengestützten Daten ermöglicht wurde. So wie häufig in der Literatur berichtet (DAUGHTRY et al., 1983; DE KOEIJER et al., 2000; WILLIAMS et al., 1989), können damit gezielt empfindliche Stadien der Pflanzenentwicklung besondere Beachtung hinsichtlich Stress in der Modellierung finden. Der multiple Einsatz von Stressfaktoren in unterschiedlichen Phasen erforderte während der Optimierung die Dimensionierung der ursprünglich als isoliert angenommenen Effekte. Die eingesetzten Größen zur Quantifizierung des Ertragsverlustes stellen somit Richtwerte dar, die entsprechend der Anzahl und der Art der eingesetzten Stressfaktoren bzw. Pflanzenentwicklungsphasen verändert werden müssen. Dies erfolgte näherungsweise über das *Simplex*-Verfahren. Letztlich ist die Anzahl an möglichen Einflussfaktoren jedoch unüberschaubar und die Auswirkungen einzelner Faktoren sind aufgrund vielfältiger Interaktionen schwer quantifizierbar.

Entgegen den Erwartungen konnte keine wesentliche Verbesserung der Ertragsprognose im erweiterten Prognosemodell erzielt werden. Dies spricht für die Dominanz und Macht der eingesetzten Wirkungsfaktoren in der Vorhersage. Das heißt, die eingesetzten Wirkungsfaktoren (NDVI) bildeten die Ertragsentwicklung derart gut ab, dass die explizite Berücksichtigung von Ursachefaktoren zu keinen entscheidenden Verbesserungen führte. Für den operationellen Einsatz und für die Berücksichtigung der Kosten-Nutzen-Relation ist anhand der hier erhaltenen Ergebnisse das einfache Ertragsprognosemodell als hinreichend anzusehen. Eine Erweiterung um Stressfaktoren könnte sich v. a. in klimatischen Ausnahmejahren als vorteilhaft herausstellen.

Es muss berücksichtigt werden, dass konventionelle Daten bzw. ihre Prozessierung ebenso wie menschlich subjektive Einschätzungen fehlerhaft sein können. So stellt beispielsweise die Regionalisierung der Daten von Punkt- zu flächenhaften Daten ein mögliches Fehlerpotential dar. Der aus ET_a und ET_p zusammengesetzte CWSI ist eine häufig verwendete Kenngröße in Wachstumssimulationsmodellen, um das Wasserangebot zu quantifizieren (JONES et al., 1997). Im

regionalen Maßstab mag der CWSI ein geeignetes Instrument sein, um Wasserstress auszudrücken. Zu beachten ist jedoch, dass die vom DWD bereitgestellte ET_a und ET_p bereits über Näherungsverfahren errechnet wurden.

Obwohl für das Sommergersten- bzw. Braugerstenaufkommen letztendlich das Flächenausmaß und der Flächenertrag ausschlaggebend sind, wurde der Verschnitt beider Größen in der vorliegenden Untersuchung nicht durchgeführt. Dies liegt darin begründet, dass eine zusätzliche flächenhafte Evaluierung der Sommergerstenklassifikation aufgrund fehlender Vergleichszahlen (Ernteerhebung in den Landkreisen) nicht möglich war. Die erfolgte Evaluierung der Klassifikation erfolgte deshalb mit Hilfe von *Ground Truth* Daten.

Das hier entwickelte Prognosesystem stützt sich sowohl auf fernerkundliche als auch auf konventionelle Daten. Der Schwerpunkt liegt dabei auf der fernerkundlichen Seite, wobei die konventionellen Daten häufig nur zur genaueren Bestimmung fernerkundlicher Größen herangezogen werden und damit vorwiegend Hilfs- oder Korrekturcharakter haben. Positive synergetische Effekte der Kombination von FE-Daten und bodengestützten Daten haben sich v. a. bei der Verwendung von *Growing-Degree-Days* gezeigt, aber auch CORINE *land cover* können positive Synergieeffekte erwartet werden, wie sie auch von GENOVESE et al. (2001) erzielt wurden. Ein rein fernerkundliches System ist allein deshalb nicht realisierbar, weil bestimmte Größen in jedem Fall auf konventionelle Einheiten zurückgeführt werden müssen (z. B. Erträge je administrativer Einheit).

Die Kosten-Nutzen-Relation des einfachen Ertragsprognosesystems ohne die Berücksichtigung von Temperatur- und Wasserstress (vergl. Kapitel 4.4.3) ist besser einzustufen als die des erweiterten Modells, wobei in beiden Fällen noch zusätzliches Kostensenkungspotential vorhanden ist. Das Ertragsprognosesystem profitiert vor allem von der freien Verfügbarkeit der NOAA-AVHRR-Daten. Das Kosten-Nutzen-Verhältnis zur Bestimmung des Flächenausmaßes wird hauptsächlich dadurch verschlechtert, als dazu hochauflösende FE-Daten unerlässlich sind. Unter wirtschaftlichen Gesichtspunkten kommt daher der Einsatz von hochauflösenden FE-Daten der zur Zeit verfügbaren operationellen FE-Systeme für die Klassifikation nur in begrenztem Umfang in Betracht, z. B. durch Beschränkung auf eine bestimmte Anzahl an Regionen, die für den Großteil der übrigen Flächen repräsentativ sind.

Ein Hemmnis für operationelle Anwendungen ist auch darin zu sehen, dass der Aufwand für die Recherche und die Beschaffung der Datengrundlage hoch ist (SCHELLING, 2000). Dies ist u. a. darauf zurückzuführen, dass die Datenquellen nicht zentral, sondern über mehrere Institutionen verstreut vorliegen. Damit verbunden ist auch der hohe Aufwand für die Datenvorprozessierung verbunden, der häufig nur dazu dient, heterogene Datenbestände zu vereinheitlichen. Mit zunehmender Entwicklung von Geodatenservern, der Etablierung digitaler Datenbestände und der

Weiterentwicklung interoperabler Systeme in GIS bzw. FE wird dieses Problem sicherlich weiter vermindert.

7 Zusammenfassung

Für die Optimierung der Einkaufspolitik der Braugersteinindustrie sind frühzeitige und objektive Informationen im Hinblick auf die zu erwarteten Braugersteernten von großer Wichtigkeit. Der Braugerstenmarkt zeigt eine hohe Dynamik in der Preisentwicklung, die in erster Linie von der Versorgungssituation abhängt. In ertragsschwachen Jahren ist der deutsche Braugerstenmarkt verstärkt auf Importe angewiesen, womit die Wertigkeit der Informationen, v. a. über ausländische Bezugsländer, nochmals ansteigt. Obwohl die Qualität der Braugerste (Eiweißgehalt, Vollgersteanteil) nicht explizit prognostiziert wurde, kann man davon ausgehen, dass Quantität und Qualität zueinander positiv korrelieren (SCHELLING et al., 2003a; SCHELLING et al., 2003b).

Da in Deutschland vorwiegend die Sommergerste (*Hordeum vulgare L.*) als Brauware verwendet wird, konzentrierten sich die Untersuchungen auf diese Kultur. Das Ernteaufkommen setzt sich aus Flächenausdehnung und Flächenerträgen zusammen. Demgemäß wurden einerseits Untersuchungen zu den Möglichkeiten der Klassifikation von Sommergerste mittels Fernerkundung durchgeführt, andererseits wurden Ernteprognosemodelle, die auf den Flächenertrag zielen, entwickelt und evaluiert.

Die Untersuchungen wurden unter dem Aspekt der Verwertbarkeit der Anwendungen durchgeführt, wobei im Besonderen auf eine mögliche Umsetzung und Operationalisierung geachtet wurde. Dies betrifft auch den ökonomischen Aspekt. Ziel der Arbeit war die Entwicklung eines prototypischen Braugersteinformationssystems, das die notwendigen Grundlagen für eine operationelle Anwendung aufweist.

Die Untersuchungsregionen lagen in Südwestdeutschland. Dabei wurde in Rheinland-Pfalz (Vorderpfalz) ein typisches Frühdruschgebiet und in Baden-Württemberg ein typisches Spätdruschgebiet untersucht.

Die Klassifikation erfolgte über multitemporale LANDSAT-Fernerkundungsdaten (TM/ETM+) unter Einbezug von wissensbasierten Regeln und einem digitalen Höhenmodell. Dabei wurde sowohl eine pixelbasierte als auch eine objektorientierte Methodik verfolgt. Problematisch waren die kleinen Strukturen im Untersuchungsgebiet bzw. die zu grobe Pixelauflösung (30 m). Um bei der genannten Auflösung Klassifikationsgenauigkeiten von Sommergerste von mindestens 57 % zu erreichen, waren in beiden Untersuchungsregionen Schlaggrößen von > 1,5 ha erforderlich. Die Spanne der Klassifikationsgenauigkeit lag zwischen 46 % und 73 % Treffergenauigkeit, wobei Unterschiede sowohl zwischen den verwendeten Algorithmen als auch zwischen den Untersuchungsregionen erkennbar waren. Demnach ist die im Anbauflächenmuster weniger artenreiche Region Baden-Württemberg genauer klassifiziert worden. Mit dem objektorientierten Ansatz gelang es, kleinere Schläge besser zu erfassen. Obschon damit auch eine Generalisierung

einhergeht, konnte mit dem objektorientierten Ansatz der bekannte *salt-and-pepper*-Effekt deutlich reduziert werden.

Die Ertragsprognosemodelle zur Vorhersage des Flächenertrages basieren auf einem empirisch-statistischen Ansatz. Dabei werden historische, vorprozessierte NOAA-AVHRR-NDVI-Maximalwertkompositen, und historische, agrarstatistische Daten in einem Regressionsmodell verrechnet. In die Vorprozessierung gehen u. a. CORINE *land cover* Daten ein. Besonders signifikante Zusammenhänge, die in bestimmten Phasen der Pflanzenentwicklung stattfinden, werden genutzt, um Ernteerträge zu prognostizieren. Die Modelle wurden in einer einfachen und in einer erweiterten Form erstellt. Letztere umfasst zusätzlich Stressfaktoren für Temperatur und Wasserversorgung, die in getrennten Submodellen errechnet werden.

Das beste Ergebnisse der Ertragsvorhersage konnte für die NDVI-Akkumulationsperiode „Kornfüllung“ erzielt werden. Die Korrelationskoeffizienten der einzelnen Landkreise lagen im Mittel bei 0,80, die erzielten durchschnittlichen Abweichungen zwischen berichteten und prognostizierten Erträgen bei 7,0 %. Damit sind Ernteprognosen 3 Wochen vor der Ernte möglich. Die Ergebnisse einer zeitlich weiter vorgezogenen Prognose (ca. 5 - 6 Wochen vor der Ernte, NDVI-Akkumulationsperiode der „maximalen photosynthetischen Aktivität“) verschlechterten sich nur geringfügig (durchschnittlich 7,7 % Abweichung). Zu beachten ist jedoch neben dem Abweichungsprozentsatz auch die Güte des Modells, die über den Korrelationskoeffizienten definiert werden kann. Eine differenzierte Betrachtung nach Landkreisen zeigt diesbezüglich deutliche Schwankungen, wonach die Ergebnisse der vorgezogenen Prognose kritisch zu interpretieren sind. Dennoch können die früheren Prognosen eine Alternative darstellen, sofern Zugeständnisse an die Prognosegenauigkeit gemacht werden.

2-Wochen-Kompositen haben sich aufgrund der reduzierten Wolkenproblematik geeigneter erwiesen als 1-Wochen-Kompositen, auch wenn dadurch ein Informationsverlust verbunden ist. Als geeignet haben sich *Growing-Degree-Days* herausgestellt, die zur Bestimmung des Eintritts phänologischer Phasen verwendet wurden und mit denen im Gegensatz zu starren Kalendertagen die Korrelationskoeffizienten zwischen NDVI-Akkumulationssummen und Ernteerträgen deutlich erhöht werden konnten. Die Verwendung von *CORINE land cover* zur Bestimmung von Ackermasken hat sich als hilfreich erwiesen.

Die Erweiterung des Modells durch zusätzliche Stressfaktoren für Temperatur und Trockenstress erbrachte geringfügige Verbesserungen der Prognoseergebnisse. Dabei wurden in mehreren sensitiven phänologischen Entwicklungsstadien Wirkungsfaktoren berücksichtigt, die auf die Temperaturansprüche und die Wasserversorgung der Sommergerste zurückgeführt werden können und Auswirkungen auf die Ertragsbildung haben. Als Faktor für Wasserstress wurde der CWSI (*Crop Water Stress Index*); für Temperaturstress wurde das Verhältnis der aktuellen Temperatur

zum langjährigen Mittel eingesetzt. Die Dimensionierung der unterschiedlichen Korrekturfaktoren für Trocken- und Temperaturstress, die letztlich die Auf- und Abwertungen des Ertrages bestimmen, wurden über ein mathematisches Verfahren (*Simplex*) optimiert. Die durchschnittliche Genauigkeit der Ertragsschätzung konnte auf 6,4 % verbessert werden, eine Betrachtung der Ergebnisse auf Landkreise zeigt jedoch für den Untersuchungszeitraum keine einheitlichen Verbesserungen. Die Datenbeschaffung und -prozessierung für die Erweiterungen des Modells sind im Verhältnis zum erreichten Gewinn an Genauigkeit aufwändig, wodurch sich das Kosten-Nutzen-Verhältnis verschlechtert. Der Einbezug von Stressfaktoren (abgeleitet aus den Ursachefaktoren Temperatur, Evapotranspiration) stellt eine Ergänzung zu den Daten des abbildenden Systems (Wirkungsfaktoren) dar. Der geringe Verbesserungseffekt kann möglicherweise darauf zurückzuführen sein, dass schon allein über die Wirkungsfaktoren die Ertragsentwicklung mit ausreichender Genauigkeit beschrieben werden kann, eine Ergänzung somit unnötig und einer Doppelkorrektur gleichkommen würde. Die Ergebnisse der erweiterten Ertragsmodellierung wurden einer Sensitivitätsanalyse unterzogen.

Die Resultate der Ertragsmodellierung sind vielversprechend. Im Vergleich zu Untersuchungen mit ähnlichen Rahmenbedingungen konnten teilweise bessere Resultate erzielt werden. Aufgrund der Methodik (Regressionsmodell) ist das Ernteprognosemodell nicht ohne Änderungen auf andere Regionen transferierbar, eine lokalspezifische Adaption ist jedoch anhand relativ einfacher Modifikationen möglich. Der notwendige Aufwand für den operationellen Einsatz dieses Systems, auch für den großflächigen Einsatz, liegt im Vergleich zu anderen, deterministischen Prognosemodellen in einem realisierbaren Rahmen.

8 Literaturverzeichnis

- AASE, J. K., SIDDOWAY, F. H., 1981: Spring wheat yield estimates from spectral reflectance measurements; IEEE Transactions on Geoscience and Remote Sensing, GE-19, 78-84;
- ARKIN, G. F., VANDERLIP, R. L., RITCHIE, J. T., 1976: A dynamic grain sorghum growth model; Transactions of ASAE, 19, 622-630;
- ARKIN, G. F., WIEGAND, C. L., HUDDLESTON H., 1977: The future role of a crop model in large area yield estimation; Proceedings of the crop Modeling workshop, 87-116; USDC-NOAA-EDIS-CEAS, Columbia, MO;
- ASRAR, G., FUCHS, M., KANEMASU, E. T., HATFIELD, J. L., 1984a: Estimating Absorbed Photosynthetic Radiation and Leaf Area Index from spectral reflectance in wheat; Agron.J., 76, 300-306;
- ASRAR, G., HIPPS, L. E., KANEMASU, E. T., 1984b: Assessing solar energy and water use efficiencies in winter wheat: a case study; Agricultural and Forest Meteorology, 31, 47-58;
- ASRAR, G., KANEMASU, E. T., JACKSON, R. D., PINTER, P. J. Jr., 1985: Estimation of total above-ground phytomass production using remotely sensed data; Remote Sens.Environ., 17, 211-220;
- ATZBERGER, C., 1997: Estimates of winter wheat production through remote sensing and crop growth modelling - A case study in the Camargue region; Akademische Abhandlungen zu den Geowissenschaften, VWF Verlag für Wissenschaft und Forschung, Berlin;
- BAATZ, M., BENZ, U., DEGHANI S., HEYNEN, M., HÖLTJE A., HOFMANN P., LINGENFELDER I., MIMLER, M., SOHLBACH M., WEBER, M., WILLHAUCK, G., 2001: eCognition - object oriented image analysis - User Guide; Definiens Imaging, München, Germany;
- BAATZ, M., SCHÄPE, A., 2000: Multiresolution Segmentation - an optimization approach for high quality multi-scale image segmentation; in: Strobl, J. Blaschke T. Griesebner G.: Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGIT-Symposium Salzburg 2000, 12-23;
- BACH, H., MAUSER, W., 1999: Ermittlung des Ernteertrags mit Fernerkundungsdaten; Az 22-8215.25, Studie im Auftrag des Ministeriums ländlicher Raum Baden Württemberg, Stuttgart;
- BAIER, W., 1977: Crop-weather models and their use in yield assessments; 458, WMO, Geneva;
- BAN, Y., HOWARTH, P. J., 1999: Multitemporal ERS-1 SAR data for crop classification: a sequential masking approach; Canadian Journal of Remote Sensing, 25, 5, 438-447;
- BARBOSA, P. M., CASTERAD, M. A., HERRERO, J., 1996: Performance of several Landsat 5 Thematic Mapper (TM) image classification methods for crop extent estimates in an irrigation district; Int.J.Remote Sensing, 17, 18, 3665-3674;
- BARET, F., GUYOT, G., 1991: Potentials and limits of vegetation indices for LAI and APAR assessment; Remote Sens.Environ., 35, 161-173;
- BARET, F., GUYOT, G., MAJOR, D. J., 1989: TSAVI: a vegetation index which minimizes soil brightness effects on LAI and APAR estimation; 12th Canadian Symp. on Remote Sensing and IGARSS '90, 10-7-1989, Vancouver, Canada;
- BARNES, E. M., PINTER, P. J. Jr., KIMBALL, B. A., WALL, G. W., LAMORTE, R. L., HUNSAKE, D. J., ADAMSEN, F., LEAVITT, S., THOMPSON, T., MATHIUS, J., 1997: Modification of CERES-Wheat to accept LAI as an input variable; 973016, ASAE, 2950 Niles Rd., St. Joseph, MI 49085-9659 USA;
- BARTHOLOME, E., 1988: Radiometric measurements and crop yield forecasting. Some observations over millet and sorghum experimental plots in Mali; Int.J.Remote Sensing, 9, 10-11, 1539-1552;
- BLASCHKE, T., STROBL J., 2001: What's wrong with pixels?: Some recent developments interfacing remote sensing and GIS; Geobit, 6, 12-17;
- BOCHENEK, Z., 2000: Operation use of NOAA data for crop condition assessment in Poland; in: Casanova J.L.: Remote Sensing in the 21st century: Economic and Environmental Applications, 387-392; Balkema, Rotterdam;
- BOOCHS, F., KUPFER, G., DOCKTER, K., KÜHBAUCH, W., 1990: Shape of the red edge as vitality indicator for plants; Int.J.Remote Sensing, 11, 1741-1753;

- BOUMAN, B. A. M., 1992: Linking physical Remote Sensing models with crop growth simulation models, applied for sugar beet; *Int.J.Remote Sensing*, 13, 14, 2565-2581;
- BRAKKE, T. W., KANEMASU, E. T., 1979: Estimated winter wheat yields from Landsat MSS using spectral techniques; *Proceedings of the 13th International Symposium on Remote Sensing of Environment*, 629-641; ERIM, Ann Arbor, MI;
- BSA, 2003: Beschreibende Sortenliste 2003; Getreide, Mais, Ölfrüchte, Leguminosen, Hackfrüchte; Bundessortenamt, Deutscher Landwirtschaftsverlag GmbH, Hannover;
- BÜKER, C., 1992: Fernerkundung von Winterweizen - Zustandsbeschreibung und Ertragsschätzung durch bodennahe Messungen; *Thesis/Diss., Univ. Bonn*;
- BULMAN, P., SMITH, D. L., 1994: Post-heading nitrogen uptake, retranslocation, and partitioning in spring barley; *Crop Sci.*, 34, 4, 977-984;
- CHAVEZ, P. S. Jr., 1996: Image-based atmospheric corrections - revisited and revised; *Photogrammetric Engineering and Remote Sensing*, 62, 9, 1025-1036;
- CHMIELEWSKI, F.-M., 1998: Der Einfluß der Witterung auf die Ertragsbildung von Sommergerste; *Mitt.Ges.Pflanzenbauwiss.*, 11, 97-98;
- CHOWDHURY, S. I., WARDLAW, I. F., 1978: The effect of temperature on kernel development in cereals; *Aust.J.Agric.Res.*, 29, 205-223;
- CHRISTENSEN, S., GOUDRIAAN, J., 1993: Deriving light interception and biomass from spectral reflectance ratio; *Remote Sens.Environ.*, 43, 87-95;
- CLEVERS, J. G. P. W., 1989: The application of a weighted infrared-red vegetation index for estimating Leaf Area Index by correcting for soil moisture; *Remote Sens.Environ.*, 29, 25-37;
- COHEN, Y., SHOSHANY, M., 2002: A national knowledge-based crop recognition in Mediterranean environment; *International Journal of Applied Earth Observation and Geoinformation*, 4, 75-87;
- COLEMAN, V. R., 1995: The use of NOAA-AVHRR in the development of a cereal yield prediction model for England and Wales; *Thesis/Diss., Cranfield University, Silsoe College*;
- CONGALTON, R. G., GREEN, K., 1999: *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*; Lewis Publishers, Boca Raton, London;
- DADHWAL, V. K., SRIDHAR, V. N., 1997: A non linear regression form for vegetation index-crop yield relation incorporating acquisition date normalization; *Int.J.Remote Sensing*, 18, 6, 1403-1408;
- DARWISH, A., LEUKERT, K., REINHARDT, W., 2003: Image Segmentation for the purpose of object-based classification; 3; 2003 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Toulouse/France, 21. - 25. July 2003, 2039-2041;
- DAUGHTRY, C. S. T., GALLO, K. P., BAUER, M. E., 1983: Spectral estimates of solar radiation intercepted by corn canopies; *Agron.J.*, 75, 527-531;
- DE KOEIJER, K. J., STEVEN, M. D., COLLS, J. J., 2000: Integration of earth observation data with a crop model for yield forecasting; *Aspects of Applied Biology*, 60, 91-98;
- DE RUITER, J. M., BROOKING, I. R., 1994: Nitrogen and dry matter partitioning of barley grown in a dryland environment; *New Zewl.J.Crop hort.Sci.*, 22, 1, 45-55;
- DE RUITER, J. M., BROOKING, I. R., 1996: Effect of sowing date and nitrogen on dry matter and nitrogen partitioning in malting barley; *New Zewl.J.Crop hort.Sci.*, 24, 1, 65-76;
- DE RUITER, J. M., STOL, W., VAN KEULEN, H., 1993: Simulation of yield and quality of malting barley; *Proc.Agron.Soc.New Zeal.*, 23, 11-19;
- DELÉCOLLE, R., GUÉRIF, M., 1988: Introducing spectral data into a plant process model for improving its prediction ability; *Proceedings of the 14th International Colloquium on spectral signatures of objects in Remote Sensing*, 125-127; ESA, Aussois, France;

- DELÉCOLLE, R., MAAS, S. J., GUÉRIF, M., BARET, F., 1992: Remote Sensing and crop production models: present trends; ISPRS Journal of Photogrammetry and Remote Sensing, 47, 145-161;
- DEMIRCAN, A., 1995: Die Nutzung fernerkundlich bestimmter Pflanzenparameter zur flächenhaften Modellierung von Ertragsbildung und Verdunstung; B 20; Münchener Geographische Abhandlungen, Reihe B, Geobuch Verlag, München;
- DENORE, B. J., MEILÁN, J. L., WILLIAMS, J. M., COLE, M., DE KOEIJER, K. J., COLLS, J. J., 2000: Estimation of cereal yields combining crop growth models and remotely sensed vegetation indices; in: Casanova J.L.: Remote Sensing in the 21st century: Economic and Environmental Applications, 371-378; Balkema, Rotterdam;
- DIEPENBROCK, W., FISCHBECK, G., HEYLAND, K.-U., KNAUER, N., 1999: Spezieller Pflanzenbau; 3., UTB für Wissenschaft, Ulmer, Stuttgart;
- DOMMERMUTH, H., TRAMPF, W., 1995: Potentielle und tatsächliche Evapotranspiration, Bodenfeuchte und Wasserstressindex; 1: Gras; Daten zum Bodenwasserhaushalt in Deutschland, 1951 - 80, DWD, Offenbach;
- DOORENBOS, J., KASSAM, A. H., 1979: Yield response to water; FAO irrigation and drainage paper, 33; FAO publications, FAO, Rome;
- DRAWERT, F., 1984: Brautechnische Analysemethoden, Methodensammlung der Mitteleuropäischen Brautechnischen Analysekommission (MEBAK); Weihenstephan;
- DUBEY, R. P., AJWANI, N., KALUBARME, M. H., SRIDHAR, V. N., NAVALGUND, R. R., MAHEY, R. K., SIDHU, S. S., JHORAR, O. P., CHEEMA, S. S., NARANG, R. S., 1994: Pre-harvest wheat yield and production estimation for the Punjab, India; Int.J.Remote Sensing, 15, 10, 2137-2144;
- DVWK, 1984: Berechnungsbedürftigkeit und Berechnungsbedarf, Modelluntersuchungen für die Klima- und Bodenbedingungen der Bundesrepublik Deutschland; 205; Merkblätter zur Wasserwirtschaft, Deutscher Verband für Wasserwirtschaft und Kulturbau, Hamburg;
- DWD, 1997: Wesentliche Punkte der Beobachtungsrichtlinien; 9; Dezember, 4, Deutscher Wetterdienst, Offenbach;
- DWD, 2003: Normalwerte ausgewählter deutscher Klimastationen; http://www.dwd.de/de/Funde/Klima/KLIS/daten/online/nat/index_normwerte.htm, Deutscher Wetterdienst;
- EAGLES, H. A., BEDGGOOD, A. G., PANOZZO, J. F., MARTIN, P. J., 1995: Cultivar and environmental effects on malting quality in barley; Aust.J.Agric.Res., 46, 5, 831-844;
- ECKERT, S., KELLENBERGER, T., 2001: Anwendung einer satellitengestützten Methode zur Ernteprognose im Kanton Waadt; Vermessung, Photogrammetrie, Kulturtechnik, 10, 640-647;
- EEA, 2003: CORINE land cover; 12/2000, European Environment Agency, <http://dataservice.eea.eu.int/>;
- EGBERT, D. D., ULABY, F. T., 1972: Effect of angles on reflectivity; Photogrammetric Engineering and Remote Sensing, 38, 556-564;
- ENGEL, T., BALDIOLI, M., 1993: Expert-N und Wachstumsmodelle; in: Reiner L., Geidel H., and Mangstl A.: Agrarinformatik, Band 24, Ulmer Verlag, Stuttgart;
- ERDAS INC., 1999: ERDAS Field Guide; 5., ERDAS Inc., Atlanta, Georgia;
- ERDAS INC., 2001: ERDAS IMAGINE - Tour Guides; ERDAS Inc., Atlanta, Georgia;
- ERICKSON, J. D., 1984: The LACIE experiment in satellite aided monitoring of global crop production; Woodwell, G. M., Wiley, Chichester;
- EU, 2003: Systematik der Gebietseinheiten für die Statistik - NUTS, Systematik der statistischen Regionen für Europa; http://europa.eu.int/comm/eurostat/ramon/nuts/home_regions_de.html, Europäische Union;
- EVANS, L. T., WARDLAW, I. F., FISCHER, R. A., 1978: Wheat; University Press, Cambridge;
- FAHRMEIR, L., HAMERLE, A., TUTZ, G., 1996: Multivariate statistische Verfahren; 2. Auflage, de Gruiter, Berlin;
- FAIVRE, R., FISCHER, A., 2002: Predicting crop reflectances using satellite data observing mixed pixels; Journal of Agricultural, Biological and Environmental Statistics, 2, 1, 87-107;

- FISCHER, A., 1994: A simple model for the temporal variations of NDVI at regional scale over agricultural countries. Validation with ground radiometric measurements; *Int.J.Remote Sensing*, 15, 7, 1421-1446;
- FOCKELMANN, R., 2002: Objektorientierte Bildanalyse zur Fuzzy-Logik basierten Landnutzungsklassifikation hochauflösender Fernerkundungsdaten; Thesis/Diss., Ludwig-Maximilians-Universität München;
- FROST, R., 1986: Introduction to knowledge base systems; Macmillan, New York;
- GEBBING, T., SCHNYDER, H., KÜHBAUCH, W., 1995: Der Einbau von Vorblüteassimilaten in die Stärke- und Reserveproteinfraktion des Weizenkornes; *Mitt.Ges.Pflanzenbauwiss.*, 8, 201-204;
- GEISLER, G., 1983: Ertragsphysiologie von Kulturarten des gemäßigten Klimas; P. Parey, Berlin;
- GENOVESE, G., VIGNOLLES, C., NÈGRE, T., PASSERA, G., 2001: A methodology for a combined use of normalised difference vegetation index and CORINE land cover data for crop yield monitoring and forecasting. A case study in Spain.; *Agronomie*, 21, 91-111;
- GEOLOGISCHES LANDESAMT BADEN-WÜRTTEMBERG, 1994: Bodenübersichtskarte von Baden-Württemberg 1 : 200 000; Geologisches Landesamt Baden-Württemberg, Freiburg i. Br.;
- GEOSYSTEMS GMBH, 2003: ATCOR; <http://www.geosystems.de/atcor/index.html>, Geosystems GmbH, Germering/D;
- GILLET, A. G., 1997: Modelling the response of winter wheat to different environments: A parsimonious approach; Thesis/Diss., Univ. of Nottingham;
- GIOVACCHINI, A., 1986: An evaluation of different green vegetation indices for wheat yield forecasting; Symposium on Remote Sensing for resources development and environmental management, 265-267; Enschede;
- GITELSON, A. A., KAUFMAN, Y. J., MERZLYAK, M. N., 1996: Use of green channel in remote sensing of global vegetation from EOS-MODIS; *Remote Sens.Environ.*, 58, 3, 289-298;
- GOWARD, S. N., MARKHAM, B., DYE, D. G., DULANEY, W., YANG, J., 1991: Normalized Difference Vegetation Index Measurements from AVHRR; *Remote Sens.Environ.*, 35, 257-277;
- GOYNE, P. J., MEINKE, H., MILROY, S. P., HAMMER, G. L., HARE, J. M., 1996: Development and use of a barley crop simulation model to evaluate production management strategies in north-eastern Australia; *Aust.J.Agric.Res.*, 47, 997-1015;
- GRAMLICH, F., 2003: personal communication;
- GRASHOFF, C., D'ANTUONO, L. F., 1997: Effect of shading and nitrogen application on yield, grain size distribution and concentrations of nitrogen and water soluble carbohydrates in malting spring barley (*Hordeum vulgare* L.); *Europ.J.Agron.*, 6, (3/4), 275-293;
- GROTEN, S. M. E., 1993: NDVI - crop monitoring and early yield assessment of Burkina Faso; *Int.J.Remote Sensing*, 14, 8, 1495-1515;
- GUANAES REGO, L. F., KOCH, B., 2003: Automatic classification of land cover with high resolution data of the Rio de Janeiro City, Brazil - comparison between pixel and object classification; in: Jürgens, C.: *Remote Sensing of Urban Areas*, 27-29 June 2003, 153-157; Regensburg;
- HALL-KÖNIVES, K., 1990: Crop monitoring in Sweden; *Int.J.Remote Sensing*, 11, 3, 461-484;
- HAMAR, D., FERENCZ, C., LICHTENBERGER, J., TARCSAI, G. I., FERENCZ-ÁRKOS, I., 1996: Yield estimation for corn and wheat in the Hungarian Great Plain using Landsat MSS data; *Int.J.Remote Sensing*, 17, 9, 1689-1699;
- HANUS, H., 1969: Ein Verfahren zur frühzeitigen Vorausschätzung von Ernteerträgen aus Witterungsdaten; *Z.Acker- u.Pflanzenbau*, 129, 101-111;
- HANUSS, K., 1973: Vorausschätzungen von Ernteerträgen aus Witterungsdaten; *Mitteilungen der DLG*, 29, 822-826;
- HATFIELD, J. L., 1983: Remote Sensing Estimators of Potential and Actual Crop Yield; *Remote Sens.Environ.*, 13, 4, 301-311;
- HAUDE, W., 1955: Zur Bestimmung der Verdunstung auf möglichst einfache Weise; *Mitteilungen des Deutschen Wetterdienstes*, 11, Deutscher Wetterdienst;

- HOLBEN, B. N., 1986: Characteristics of maximum value composite images from temporal AVHRR data; *Int.J.Remote Sensing*, 11, 1511-1520;
- HOLM, O., 2003a: Mälzereien in Deutschland - Marktchancen und Gefahren, Teil 1; *Brauwelt*, 33, 1043-1048;
- HOLM, O., 2003b: Mälzereien in Deutschland - Marktchancen und Gefahren, Teil 2; *Brauwelt*, 34/35, 1084-1089;
- HSIAO, T. C., 1973: Plant responses to water stress; *Ann.Rev.Plant Physiol.*, 24, 519-570;
- HUETE, A., 1988: A soil adjusted vegetation index (SAVI); *Remote Sens.Environ.*, 25, 295-309;
- HÜNTING, K., WEISSTEINER, C. J., KÜHBAUCH, W., 2003: Yield prediction of malting barley based on meteorological data; 1; 2003 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Toulouse/France, 21. - 25. July 2003, 383-385;
- HUTTENLOCHER, F., 1959: Die naturräumlichen Einheiten auf Blatt 178 Sigmaringen; *Geographische Landesaufnahme 1 : 200 000 - Naturräumliche Gliederung Deutschlands*, Bundesanstalt für Landeskunde, Remagen;
- IDSO, S. B., HATFIELD, J. L., REGINATO, R. J., JACKSON, R. D., 1978: Wheat yield estimation by albedo measurement; *Remote Sens.Environ.*, 7, 273-276;
- ILLERA, P., DELGADO, J. A., FERNÁNDEZ UNZUETA, A., FERNÁNDEZ MANSO, A. A., 2000: Integration of NOAA-AVHRR and meteorological data in a GIS - Application for vegetation monitoring in Castilla y León, Spain; in: Casanova J.L.: *Remote Sensing in the 21st century: Economic and Environmental Applications*, 47-54; Balkema, Rotterdam;
- JACKSON, R. D., 1982: Canopy temperature and crop water stress; in: Hillel D.: *Advances in irrigation*, 43-85; Academic, New York;
- JACKSON, R. D., PINTER, P. J. Jr., 1986: Spectral response of architecturally different wheat canopies; *Remote Sens.Environ.*, 9, 87-91;
- JAGGARD, K. W., CLARK, C. J., 1990: Remote sensing to predict the yield of sugar beet in England; in: Steven, M. D. and Clark, J. A.: *Applications of Remote Sensing in Agriculture*, 201-208; Butterworths, London;
- JENSEN, A., LORENZEN, B., 1990: Radiometric estimation of biomass and nitrogen content of barley grown at different nitrogen levels; *Int.J.Remote Sensing*, 11, 10, 1809-1820;
- JENSEN, J. R., 1996: Introductory digital image processing – a Remote Sensing perspective; 2., in: Clarke, K. C.: *Series in Geographic Information Science*, Prentice Hall, New Jersey;
- JENSEN, J. R., 2000: *Remote Sensing of the environment: an earth resource perspective*; Earth sciences - Remote Sensing, Prentice-Hall, Inc., Upper Saddle River, NJ 07458;
- JEWELL, N., 1989: An evaluation of multi-date SPOT data for agriculture and land use mapping in the United Kingdom; *Int.J.Remote Sensing*, 10, 6, 939-951;
- JONES, P. G., THORNTON, P. K., HILL, P., 1997: Agro-meteorological models: crop growth and stress indices; *Crop yield forecasts methods*, Villefranche-sur-Mer, 24 - 27 October 1994, 53-65; Office for Official Publications of the European Communities, Luxembourg;
- KANEMASU, E. T., ASRAR, G., FUCHS, M., 1985: Application of remotely sensed data in wheat growth modelling; in: Day, W. and Atkin R.K.: *Wheat growth modelling*, 357-369; Plenum Press, New York;
- KEIL, M., MOHAUPT-JAHR, B., KIEFL, R., STRUNZ, G., 2002: Das Projekt CORINE land cover 2000 in Deutschland; *Tagungsband 19. DFD-Nutzerseminar*, 15.-16. Oktober 2002, Oberpfaffenhofen, 95-104;
- KLEMAN, J., FAGERLUND, E., 1987: Influence of different nitrogen and irrigation treatments on the spectral reflectance of barley; *Remote Sens.Environ.*, 21, 1-14;
- KLOB, M., 1987: *Wirkung der Witterung auf die Qualität von Braugerste in zwei Dauerversuchen sowie Untersuchungen zu den Möglichkeiten einer Qualitätsprognose*; Thesis/Diss., Univ. Halle;
- KOCH, B., JOCHUM, M., IVITS, E., DEES, M., 2003: Pixelbasierte Klassifizierung im Vergleich und zur Ergänzung zum objektorientierten Verfahren; *Photogrammetrie, Fernerkundung, Geoinformation*, 3, 195-204;

- KOCH, B., IVITS, E., 2002: What can remote sensing provide for biodiversity assessment; ForestSAT Symposium, August 5th - 9th, 2002, Heriot Watt University, Edinburgh,
- KOGAN, F. N., 2001: Operational Space Technology for global vegetation assessment; Bulletin of the American Meteorological Society, 82, 9, 1950-1964;
- KÜHBAUCH, W., 1999: Erfassung der Intensität landwirtschaftlicher Bodennutzung mit Hilfe der Fernerkundung; 87-96; Verlag Dr Friedrich Pfeil, München;
- KÜHBAUCH, W., DOCKTER, K., MÜLLER, C., SARX, H. G., SCHELLING, K., 1998: Abschlußbericht zum Forschungsvorhaben "Integration von MOMS-2P-Aufnahmen in ein Landwirtschaftliches Geographisches Informationssystem zur Zustandsbeschreibung, Ertrags- und Qualitätsabschätzung von Braugerstenbeständen"; Friedrich Weissheimer Malzfabrik und Lehrstuhl f. Allg. Pflanzenbau der Uni Bonn, Andernach;
- KÜHBAUCH, W., KUPFER, G., BOOCHS, F., BÜKER, C., DOCKTER, K., SCHELLBERG, J., 1991: Abschlußbericht zum Forschungsvorhaben Ertragsschätzung an landwirtschaftlichen Kulturpflanzenbeständen mit Hilfe der Fernerkundungstechnik; Lehrstuhl f. Allg. Pflanzenbau und Inst. f. Photogrammetrie der Univ. Bonn, Bonn;
- KÜHBAUCH, W., KUPFER, G., SCHELLBERG, J., MÜLLER, U., DOCKTER, K., TEMPELMANN, U., 1990: Fernerkundung in der Landwirtschaft; Luft- und Raumfahrt, 4, 36-45;
- KUITTINEN, R., MATIKAINEN, L., KESKISARJA, V., PARMES, E., PERDIGAO, V., 2000: Integration of satellite data and administrative information in crop yield monitoring; in: Casanova J.L.: Remote Sensing in the 21st century: Economic and Environmental Applications, 379-385; Balkema, Rotterdam;
- KUMAR, M., MONTEITH, J. L., 1981: Remote sensing of crop growth; in: Smith H.: Plants and the daylight spectrum, 133-144; Academic Press, New York;
- LANDAU, S., MITCHELL, R. A. C., BARNETT, V., COLLS, J. J., CRAIGON, J., MOORE, K. L., PAYNE, R. W., 1998: Testing winter wheat simulation models' prediction against observed UK grain yields; Agricultural and Forest Meteorology, 89, 85-99;
- LEVINE, N., 1999: Crimestat: A spatial statistics program for the analysis of crime incident locations; Ned Levine & Associates Anandale, and the National Institute of Justice, VA and Washington, DC;
- LILLESAND, T. M., KIEFER, R. W., 1999: Remote Sensing and image interpretation; 4., John Wiley & Sons, Inc., New York;
- LINKER, S., 2002: Braugerste am Anfang einer Super-Hausse?; <http://www.agrarberatung-hessen.de/markt/analysen/2002/01012002100902.html>, Hessisches Dienstleistungszentrum für Landwirtschaft, Gartenbau und Naturschutz; D-34117 Kassel;
- LINKER, S., 2003: Braugerste: Weltweiter Bierdurst bietet gute Marktchancen; <http://www.agrarberatung-hessen.de/markt/analysen/2003/01012003081401.html>, Hessisches Dienstleistungszentrum für Landwirtschaft, Gartenbau und Naturschutz; D-34117 Kassel;
- LOBELL, D. B., HICKE, J. A., ASNER, G. P., FIELD, C. B., TUCKER, C. J., LOS, O., 2002: Satellite estimates of productivity and light use efficiency in United states agriculture, 1982-98; Global Change Biology, 8, 722-735;
- LOOMIS, R. S., CONNOR, D. J., 1992: Crop ecology - productivity and management in agricultural systems; Cambridge Univ. Press, Cambridge;
- MAAS, S. J., 1988a: Use of remotely-sensed information in agricultural crop growth models; Ecological Modelling, 41, 247-268;
- MAAS, S. J., 1988b: Using satellite data to improve model estimates of crop yield; Agron.J., 80, 655-662;
- MAAS, S. J., 1992: GRAMI: A crop growth model that can use remotely sensed information; Agricultural Research Service, ARS-91, U.S.Department of Agriculture, National Technical Information Service, Springfield VA;
- MAAS, S. J., 1993: Parameterized model of gramineous crop growth: II: within-season simulation calibration; Agron.J., 85, 354-358;
- MAAS, S. J., ARKIN, G. F., 1978: User's guide to SORGF: a dynamic grain sorghum growth model with feedback capacity; TAES Program and Model Documentation; 78, 1;
- MAC DONALD, R. B., HALL, F. G., 1980: Global Crop Forecasting; Science, 208, 670-679;

- MANDL, P., 1998: Modellierung und Simulation mit GIS; *Geobit*, 7, 36-39;
- MANDL, P., 2000: Geo-Simulation - Experimentieren und Problemlösen mit GIS-Modellen; *Angewandte Geographische Informationsverarbeitung XII*, Salzburg;
- MANJUNATH, K. R., POTDAR, M. B., PUROHIT, N. L., 2002: Large area operational wheat yield model development and validation based on spectral and meteorological data; *Int.J.Remote Sensing*, 23, 15, 3023-3038;
- MASELLI, F., ROMANELLI, S., BOTTAI, L., MARACCHI, G., 2000: Processing of GAC NDVI data for yield forecasting in the Sahelian region; *Int.J.Remote Sensing*, 21, 18, 3509-3523;
- MATSUDA, K., RAYAN, A., 1990: Anatomy: A key factor regulating plant tissue response to water stress; in: Katterman, F.: *Environmental Injury to Plants*, Academic Press, San Diego;
- MEINEL, G., HENNERSDORF, J., 2002: Bodenbedeckung und -nutzung, Grundinformationen für die Planung - zum Stand der europäischen Nomenklaturdebatte; in: Schrenk, M.: *CORP 2002 Geo-Multimedia - Computergestützte Raumplanung. Beiträge zum 7. Symposium zur Rolle der Informationstechnologie in der und für die Raumplanung, 27.2. - 1.3.2002*, TU Wien, 179-188; Technische Universität Wien, Wien;
- MITTELBERG, B., 2001: Objektorientierte Klassifikation von Fernerkundungsdaten urbaner Räume - Möglichkeiten und Grenzen; *Thesis/Diss.*, Univ. Bonn, Geographisches Institut;
- MLR, 1995: Einsatz von Satellitendaten zur parzellenscharfen Bestimmung der Bodennutzung und Ertragsermittlung; O-Nr. 41-89.41, Ministerium für Ländlichen Raum, Ernährung, Landwirtschaft und Forsten Baden-Württemberg, Stuttgart;
- MODELKINETIX, 2000: *Model Maker - User Manual*; Cherwell Scientific Limited, Oxford, UK;
- MONTEITH, J. L., 1977: Climate and the efficiency of crop production in Britain; *Phil.Trans.R.Soc.Lond.B*, 281, 277-294;
- MOULIN, S., BONDEAU, A., DELÉCOLLE, R., 1998: Combining agricultural crop models and satellite observations: from field to regional scales; *Int.J.Remote Sensing*, 19, 6, 1021-1036;
- MÜLLER, C., 2000: Der Beitrag der Fernerkundung zur Qualitätsschätzung von Braugerste; *Thesis/Diss.*, Univ. Bonn;
- MÜLLER, U., 1989: Klassifizierung landwirtschaftlicher Nutzungen mit multispektralen Satellitendaten; *Thesis/Diss.*, Univ. Bonn, Institut für Photogrammetrie;
- MURTHY, C. S., THIRUVENGADACHARI, S., RAJU, P. V., JONNA, S., 1996: Improved ground sampling and crop yield estimation using satellite data; *Int.J.Remote Sensing*, 17, 5, 945-956;
- NARZISS, L., 1976: *Die Bierbrauerei - Die Technologie der Malzbereitung*; 6, 1; Enke Verlag, Stuttgart;
- NASA, 2003: *Landsat 7 Science Data Users Handbook*; http://ltpwww.gsfc.nasa.gov/IAS/handbook/handbook_toc.html, NASA, Washington, D.C., USA;
- NELDER, J. A., MEAD, R., 1965: A simplex method for function minimization; *Computer Journal*, 7, 307-313;
- NIEMEYER, I., 2001: Satelliten und nukleare Kontrolle - Änderungsdetektion und objektorientierte, wissensbasierte Klassifikation von Multispektralaufnahmen zur Unterstützung der nuklearen Verifikation; 28; *Schriftenreihe des Forschungszentrums Jülich, Reihe Umwelt/Environment*, Forschungszentrum Jülich,
- OEHMICHEN, J., 1986: *Pflanzenproduktion - Produktionstechnik*; 2; Paul Parey, Berlin;
- PALMER, G., 1989: *Cereals in Malting and Brewing*; in: Palmer, G.: *Cereal Science and Technology*, Aberdeen University Press, Aberdeen;
- PATEL, N. K., RAVI, N., NAVALGUND, R. R., DASH, R. N., DAS, K. C., PATNAIK, S., 1991: Estimation of rice yield using IRS-1A digital data in coastal tract of Orissa; *Int.J.Remote Sensing*, 12, 11, 2259-2266;
- PEMÖLLER, A., 1969: *Die naturräumlichen Einheiten auf Blatt 160 Landau i. d. Pfalz*; *Geographische Landesaufnahme 1 : 200 000 - Naturräumliche Gliederung Deutschlands*, Bundesforschungsanstalt für Landeskunde, Bad Godesberg;
- PESTEMALCI, V., DINC, U., YEGINGIL, I., KANDIRMAZ, M., CULLU, M. A., ÖZTÜRK, N., AKSOY, E., 1995: Acreage estimation of wheat and barley fields in the province of Adana, Turkey; *Int.J.Remote Sensing*, 16, 6, 1075-1085;

- PINTER, P. J. Jr., JACKSON, R. D., IDSO, S. B., REGINATO, R. J., 1981: Multidate spectral reflectance as predictors of yield in water stressed wheat and barley; *Int.J.Remote Sensing*, 2, 43-48;
- QI, J., CABOT, F., MORAN, M. S., DEDIEU, G., 1995: Biophysical parameter estimation using multidirectional spectral measurements; *Remote Sens.Environ.*, 54, 71-83;
- QUADE, J., 1993: *Faustzahlen für Landwirtschaft und Gartenbau*; 12., Landwirtschaftsverlag, Münster-Hiltrup;
- QUARMBY, N. A., MILNES, M., HINDLE, T. L., SILLEOS, N., 1993: The use of multi-temporal NDVI measurements from AVHRR data for crop yield estimation and prediction; *Int.J.Remote Sensing*, 14, 2, 199-210;
- RELIN, A., 1996: *Kontrolle flächengestützter Beihilfen in der Landwirtschaft durch Satellitenfernerkundung*; 8; Pohlmann, J. M., Friedrich, H., and Begemann, F., *Schriftenreihe: Informationsmanagement in den Agrarwissenschaften, Zentralstelle für Agrardokumentation und -information (ZADI)*, Bonn;
- REYNOLDS, C. A., YITAYEW, M., SLACK, D. C., HUTCHINSON, C. F., HUETE, A., PETERSEN, M. S., 2000: Estimating crop yields and production by integrating the FAO crop specific water balance model with real-time satellite data and ground based ancillary data; *Int.J.Remote Sensing*, 21, 18, 3487-3508;
- RICHARDSON, A. J., WIEGAND, C. L., 1977: Distinguishing vegetation from soil background information; *Photogrammetric Engineering and Remote Sensing*, 43, 1541-1552;
- RICHTER, R., 2002: *ATCOR for ERDAS IMAGINE - Atmospheric and Topographic Correction - ATCOR2 and ATCOR3 (Version 2.0) User Manual*; Geosystems GmbH, Germering, Germany;
- ROUSE, J. W., HAAS, R. H., SCHELL, J. A., DEERING, D. W., HARLAN, J. C., 1974: Monitoring the vernal advancement of retrogradation of natural vegetation; *NASA/GSFC, Greenbelt, MD*;
- RUDORFF, B. F. T., BATISTA, G. T., 1990: Yield estimation of sugarcane based on agrometeorological-spectral models; *Remote Sens.Environ.*, 33, 183-192;
- RUSS, J., 1995: *The image processing handbook*; CRC Press, Boca Raton;
- RUSSELL, G., 1990: *Barley knowledge base*; Joint Research Centre of the European Commission, Ispra, Italien;
- SAVIN, R., NICOLAS, M. E., 1996: Effects of short periods of drought and high temperature on grain growth and starch accumulation of two malting barley cultivars; *Aust.J.Plant Physiol.*, 23, 2, 201-210;
- SAVIN, R., STONE, P. J., NICOLAS, M. E., 1997: Grain growth and malting quality of barley. 1. Effects of heat stress and moderately high temperature; *Aust.J.Agric.Res.*, 48, 5, 615-624;
- SCHELLBERG, J., 1990: *Die spektrale Reflexion von Winterweizen - ein Beitrag zur Zustandsbeschreibung landwirtschaftlicher Kulturpflanzenbestände durch Fernerkundung*; Thesis/Diss., Univ. Bonn;
- SCHELLBERG, J., KÜHBAUCH, W., 1991: Reflexionsmessungen von Weizenbeständen zum Zwecke der fernerkundlichen Zustandsbeschreibung und Ertragsschätzung; 1; in: Kühbauch W. and Dockter K.: *Berichte der Gesellschaft für Informatik in der Land-, Forst- und Ernährungswissenschaft*, 61-68;
- SCHELLING, K., 2000: *Aufbau eines operationellen fernerkundungs- und GIS-gestützten Systems zur Zustandsbeschreibung, Ertrags- und Qualitätsabschätzung von Braugerstenbeständen*; Thesis/Diss., Univ. Bonn;
- SCHELLING, K., BORN K., WEISSTEINER C.J., KÜHBAUCH, W., 2003a: Relationships between yield and quality parameters of malting barley (*Hordeum vulgare* L.) and phenological and meteorological data; *J.Agronomy & Crop Science*, 189, 113-122;
- SCHELLING, K., WEISSTEINER, C. J., HÜNTING, K., KÜHBAUCH, W., 2003b: Yield and quality estimation of malting barley based on Remote Sensing and GIS; in: Benes, T.: *Geoinformation for European-wide Integration, Proceedings of 22nd EARSeL Symposium, Prague, 549-555*; Millpress, Rotterdam, Netherlands;
- SCHILL MALZ, 2002: *Marktbericht September 2002*; <http://www.schill-malz.de/admin/marktberichte/1.pdf>, Schill-Malz GmbH & Co. KG, D-67574 Osthofen;
- SCHILL MALZ, 2003: *Marktbericht August 2003*; <http://www.schill-malz.de/admin/marktberichte/24.pdf>, Schill-Malz GmbH & Co. KG, D-67574 Osthofen;
- SCHOTT, J. R., 1997: *Remote Sensing: The image chain approach*; Oxford, NY;

- SEILER, R. A., KOGAN, F. N., GUO WEI, 2000: Monitoring weather impact and crop yield from NOAA AVHRR data in Argentina; *Adv.Space Res.*, 26, 7, 1177-1185;
- SELLERS, P. J., BERRY, J. A., COLLATZ, C. J., FIELD, C. B., HALL, F. G., 1992: Canopy reflectance, photosynthesis and transpiration. Part III: A reanalysis using enzyme kinetics - electron transport models of leaf physiology; *Remote Sens.Environ.*, 42, 187-216;
- SELLERS, P. J., LOS, O., TUCKER, C. J., JUSTICE, C. O., DAZLICH, D. A., COLLATZ, C. J., RANDALL, D. A., 1996a: A revised land surface parameterization (SiB2) for atmospheric GCMs. Part II: The generation of global fields of terrestrial biophysical parameters from satellite data; *Journal of Climate*, 9, 706-737;
- SELLERS, P. J., RANDALL, D. A., COLLATZ, C. J., BERRY, J. A., FIELD C.B., DAZLICH, D. A., ZHANG C., COLELLO, G. D., 1996b: A revised land surface parameterization (SiB2) for atmospheric GCMs. Part 1: Model formulation; *Journal of Climate*, 9, 676-705;
- SHACKELFORD, A. K., DAVIS, C. H., 2003: A hierarchical fuzzy classification approach for high-resolution multispectral data over urban areas; *IEEE Transactions on Geoscience and Remote Sensing*, 51, 9, 1920-1932;
- SHARMA, T., SUDHA, K. S., RAVI, N., NAVALGUND, R. R., TOMAR, K. P., CHAKRAVARTY, N. V. K., DAS, D. K., 1993: Procedures for wheat yield prediction using Landsat MSS and IRS-1A data; *Int.J.Remote Sensing*, 14, 13, 2509-2518;
- SPIERZ, J. H. J., 1974: Grain growth and distribution of dry matter in the wheat plant as influenced by temperature, light energy and ear size; *Neth.J.Agric.Sci.*, 22, 207-220;
- STANKIEWICZ, K., DABROWSKA-ZIELINSKA K., GRUSZCZYNSKA, M., HOSCILO, A., 2003: Mapping vegetation of wetland ecosystem by fuzzy classification of optical and microwave satellite images supported by various ancillary data; 4879; in: Owe, M., D'Urso, G., and Toullos, L.: *Remote Sensing for Agriculture, Ecosystems and Hydrology IV*, 352-361;
- STEVEN, M. D., JAGGARD, K. W., 1995: Advances in crop monitoring by Remote Sensing; in: Danson F.M., Plummer S. E.: *Advances in Environmental Remote Sensing*, 9, 143-156; John Wiley & Sons Ltd., Chichester;
- STÖHR, W. Th., 1966: Übersichtskarte der Bodentypen-Gesellschaften von Rheinland-Pfalz; Geologisches Landesamt Rheinland-Pfalz, Mainz;
- SUPIT, I., HOOIJER, A. A., VAN DIEPEN, C. A., 1994: System description of the WOFOST 6.0 crop simulation model implemented CGMS; Office for Official Publications of the European Commission, Luxembourg;
- SWAIN, P. H., DAVIS, S. M., 1978: *Remote Sensing: The quantitative approach*; 166-174; McGraw-Hill, New York;
- TOMLIN, D., 1990: *Geographic Information Systems and Cartographic Modeling*; Prentice Hall, Engelwood Cliffs;
- TOULIOS, L., TOURNAVITI, A. N., 2003: Cereals discrimination based on spectral measurements; 4879; in: Owe, M., D'Urso, G., and Toullos L.: *Proceedings of SPIE - Remote Sensing for Agriculture, Ecosystems, and Hydrology IV*, 53-61; 22-9-2002,
- TUCKER, C. J., HOLBEN, B. N., 1980: Relationship of spectral data to grain yield variation; *Photogrammetric Engineering and Remote Sensing*, 46, 5, 657-666;
- UNGANAI, L. S., KOGAN, F. N., 1998: Drought Monitoring and corn yield estimation in Southern Africa from AVHRR Data; *Remote Sens.Environ.*, 63, 219-232;
- VANDERLIP, R. L., ARKIN, G. F., 1977: Simulating accumulation and distribution of dry matter in grain sorghum; *Agron.J.*, 69, 917-923;
- VARLET-GRANCHER, C., BONHOMME, R., CHARTIER, M., ARTIS, P., 1982: Efficience de la conversion de l'énergie solaire par un couvert végétal; *Acta Oecologia.Oecol.Plant.*, 3, 3-26;
- WARDLAW, I. F., DAWSON, I. A., MUNIBI, P., FEWSTER, R., 1989: The tolerance of wheat to high temperatures during reproductive growth. 1. Survey procedures and general response patterns; *Aust.J.Agric.Res.*, 40, 1-13;
- WHEELER, T. R., HONG, T. D., ELLIS, R. H., BATTS, G. R., MORISON, J. I. L. Hadley P., 1996: The duration and rate of grain growth, and harvest index, of wheat (*Triticum aestivum* L.) in response to temperature and CO₂; *J.Experim.Bot.*, 47, 298, 623-630;
- WIEGAND, C. L., RICHARDSON, A. J., 1984: Leaf Area, Light Interception, and yield estimates from spectral components analysis; *Agron.J.*, 76, 4, 543-548;

- WIEGAND, C. L., RICHARDSON, A. J., ESCOBAR, D. E., GERBERMANN, A. H., 1991: Vegetation indices in crop assessment; Remote Sens. Environ., 35, 105-119;
- WIEGAND, C. L., RICHARDSON, A. J., JACKSON, R. D., PINTER, P. J. Jr., AASE, J. K., SMIKA, E Darryl, LAUTENSCHLAGER, L. L., MCMURTREY, J. E. III, 1986: Development of agrometeorological crop model inputs from remotely sensed information; IEEE Transactions on Geoscience and Remote Sensing, GE-24, 90-98;
- WIEGAND, C. L., RICHARDSON, A. J., KANEMASU, E. T., 1979: Leaf Area Index estimates for wheat from LANDSAT and their implications for evapotranspiration and crop modeling; Agron.J., 71, 2, 336-342;
- WILLEKENS, A., VAN ORSHOVEN, J., FEYEN, J., 1998: Estimation of the phenological calendar, Kc-curve and temperature sums for cereals, sugar beet, potato, sunflower and rapeseed across Pan Europe, Turkey and the Maghreb countries by means of transfer procedures; Volume I, Project Report, MARS-project, Joint Research Centre of the European Communities, Space Applications Institute, Ispra;
- WILLIAMS, G. D. V., JOYNT, M. I., MCCORMICK, P. A., 1975: Regression analyses of Canadian Prairie crop-district cereal yields, 1961-1972, in relation to weather, soil and trend; Can.J. Soil Sci., 55, 43-53;
- WILLIAMS, J. M., DENORE, B. J., MEILÁN, J. L., COLLS, J. J., DE KOEIJER, K J, 2002: Cereal Yield Estimation System (Cereal YES); <http://www3.logica.com/papers/CYES/CYES.html>, Logica papers;
- WILLIAMS, J. R., JONES, C. A., KINIRY, J. R., SPANEL, D. A., 1989: The EPIC crop growth model; Transactions of ASAE, 32, 2, 497-511;
- ZADOCK, J. C., CHANG, T. T., KONZAK C.F., 1974: A decimal code for growth stages of cereals; Weed Research, 14, 415-421;

9 Anhang

Anhangstabellenverzeichnis

Tabelle A 1: Spezifikationen des Feldspektrometers	110
Tabelle A 2: Parameter des <i>Map Models</i>	110
Tabelle A 3: Parameter der inhärenten Projektion	110
Tabelle A 4: Parameter der Zielprojektion Gauss-Krüger, Zone 3.....	110
Tabelle A 5: Fehlermatrix der Vorklassifikation (Untersuchungsregion RLP).....	111
Tabelle A 6: Fehlermatrix der Vorklassifikation (Untersuchungsregion BW).....	111
Tabelle A 7: Fehlermatrix der objektorientierten Klassifikation (Untersuchungsregion RLP).....	112
Tabelle A 8: Fehlermatrix der objektorientierten Klassifikation (Untersuchungsregion BW).....	113
Tabelle A 9: Zeiträume für die Akkumulation der NDVI-Werte	114
Tabelle A 10: Bedingungen der Ableitung der Bodenwasserklassen aus regionaler Bodenkarte BW (BÜK200)	114
Tabelle A 11: Bedingungen der Ableitung der Bodenwasserklassen aus regionaler Bodenkarte BW (BÜK200) nach Bodenart	115
Tabelle A 12: Bedingungen der Ableitung der Bodenwasserklassen aus regionalen Bodenkarte RLP	116
Tabelle A 13: Nutzbare Feldkapazität [mm] der vom DWD für die Berechnung der tatsächlichen Evapotranspiration (ETa) zugrundegelegten Bodenarten	116
Tabelle A 14: Monatliche bzw. jährliche relative Umrechnungsfaktoren für die tatsächliche Evapotranspiration (ETa) von der Bodenart „lehmiger Sand“ auf andere Bodenarten	116
Tabelle A 15: Prognosefehler als prozentuale Abweichung von prognostiziertem zu berichtetem Sommergerstenertrag des einfachen und erweiterten Ertragsprognosemodells der Jahre 1995 – 2002.	117

Tabelle A 1: Spezifikationen des Feldspektrometers

Spezifikation	<i>Field Spec VNIR-512</i>
Anzahl der Spektralkanäle	512
Spektrale Auflösung	2,5 nm
Aufnahmeintervall	1,4 nm
Öffnungswinkel	18 °
Räumlicher Aufnahmebereich	80 cm im Ø bei 2 m Höhe
Messdauer (Integrationszeit)	In Abhängigkeit der gegebenen Einstrahlung ausgewählt
Referenz	Spectralon

Tabelle A 2: Parameter des *Map Models*

Map Model		Einheiten
ULX	-668 431,429	Meter
LLY	458 863,162	Meter
Pixelgröße	1 113,2	Meter
Projektion	Stereographisch	

Tabelle A 3: Parameter der inhärenten Projektion

Projektion	Stereographisch
Sphäroid	Sphäre mit 6 378 137 m
Datum	Undefiniert
Bezugsmeridian	15° 00 00 E
Bezugsbreitengrad	51° 00 00 N
Längenschiebung	0
Breitenverschiebung	0

Tabelle A 4: Parameter der Zielprojektion Gauss-Krüger, Zone 3

Projektion	Transverse Mercator
Sphäroid	Bessel
Datum	Potsdam (Rauenberg)
Bezugsmeridian	9° 00 00 E
Bezugsbreitengrad	0° 00 00 N
Längenschiebung	3 500 000
Breitenverschiebung	0

Tabelle A 5: Fehlermatrix der Vorklassifikation (Untersuchungsregion RLP)

klassifiziert	Referenz					Wald	Summe	Klasse	Producers		Users Accuracy ²
	unklass.	Wasser	Siedlung	landw. Nutzfl.	Wald				Accuracy ¹	Users Accuracy ²	
unklassifiziert	0	0	0	0	0	0	0	unklassifiziert	---	---	---
Wasser	0	70	0	0	0	0	70	Wasser	98,59%	100,00%	100,00%
Siedlung	0	1	64	38	1	104	104	Siedlung	95,52%	61,54%	61,54%
landw. Nutzfl.	0	0	3	117	2	122	122	landw. Nutzfl.	74,52%	95,90%	95,90%
Wald	0	0	0	2	60	62	62	Wald	95,24%	96,77%	96,77%
Summe	0	71	67	157	63	358	358	Overall Classification Accuracy ³ : 86,87%			
								Overall Kappa Statistics ⁴ : 0,82			

Tabelle A 6: Fehlermatrix der Vorklassifikation (Untersuchungsregion BW)

klassifiziert	Referenz					Wald	Summe	Klasse	Producers		Users Accuracy ²
	unklass.	Siedlung	landw. Nutzfl.	Wald	Summe				Accuracy ¹	Users Accuracy ²	
unklassifiziert	0	0	0	0	0	0	0	unklassifiziert	---	---	---
Siedlung	0	39	10	0	49	49	49	Siedlung	92,86%	79,59%	79,59%
landw. Nutzfl.	0	3	91	1	95	95	95	landw. Nutzfl.	89,22%	95,79%	95,79%
Wald	0	0	1	58	59	59	59	Wald	98,31%	98,31%	98,31%
Summe	0	42	102	59	203	203	203	Overall Classification Accuracy ³ : 92,61%			
								Overall Kappa Statistics ⁴ : 0,88			

¹⁾ Producers Accuracy: Anteil der klassifizierten Pixel an den bekannten Referenzpixel der Klasse *i*.

²⁾ Users Accuracy: Anteil der klassifizierten Pixel der Klasse *i* an den insgesamt klassifizierten Pixel dieser Klasse.

³⁾ Overall Classification Accuracy: über alle Klassen gemittelte Klassifikationsgenauigkeit.

⁴⁾ Overall Kappa Statistics: Verbesserung der Klassifikationsgenauigkeit gegenüber einer zufälligen Klassifikationsgenauigkeit. (CONGALTON & GREEN, 1999)

Tabelle A 7: Fehlermatrix der objektorientierten Klassifikation (Untersuchungsregion RLP)

klassifiziert	Referenz													Sum		
	SG	WW	Wein	Raps	Mais	Kart	ZR	WR	Tab	GL	L-Wald	N-Wald	Versieg1		Versieg2 (VK)	Wasser
SG	51	2	0	0	0	1	2	2	0	0	0	0	0	1	0	59
WW	1	47	1	0	0	1	1	0	2	0	0	0	2	3	0	58
Wein	0	1	11	0	0	3	3	0	6	0	0	0	0	0	0	24
Raps	2	8	0	11	1	0	0	0	1	0	0	0	0	1	0	24
Mais	2	9	0	0	2	0	2	0	0	0	0	0	0	0	0	15
Kart	5	1	0	0	1	19	22	0	8	0	0	0	0	0	0	56
ZR	1	0	0	0	1	0	33	0	1	0	0	0	0	0	0	36
WR	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	3
Tab	0	0	0	0	1	1	3	0	12	0	0	0	0	0	0	17
GL	0	0	0	0	2	0	0	0	0	3	0	0	1	1	0	7
L-Wald	0	1	0	0	1	0	0	0	0	6	0	0	0	2	0	10
N-Wald	0	0	0	0	0	0	0	0	0	0	15	0	0	2	0	17
Versieg1	2	0	0	0	0	0	0	0	0	0	0	0	9	3	0	14
Versieg2 (VK)	4	1	0	0	1	6	2	0	0	0	0	0	0	0	0	14
Wasser	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	2
unklass.	9	2	0	0	0	5	1	0	2	0	0	0	0	1	0	20
Summe	77	75	12	11	10	36	69	2	32	3	6	15	12	14	2	376
Accuracy																
Producer	0,86	0,81	0,46	0,46	0,13	0,34	0,92	0,00	0,71	0,43	0,60	0,88	0,64	0,00	1,00	
User	0,66	0,63	0,92	1,00	0,20	0,53	0,48	0,00	0,38	1,00	1,00	1,00	0,75	0,00	1,00	
Overall Accuracy	0,59															
Overall Kappa	0,54															

Abkürzungen:

SG...Sommergerste,

WW...Winterweizen,

Kart...Kartoffel,

ZR...Zuckerrübe,

WR...Winterroggen,

Tab...Tabak,

GL...Grünland,

L-Wald...Laubwald,

N-Wald...Nadelwald,

Versieg1...Versiegelungsflächen

ohne Verkehrswege,

Versieg2...Versiegelungsflächen

mit Verkehrswege,

VK... Verkehrswege

Tabelle A 8: Fehlermatrix der objektorientierten Klassifikation (Untersuchungsregion BW)

klassifiziert	Referenz											Sum	
	SG	WW	Mais	GL	Hafer	WG	Raps	Versieg1	Versieg2 (VK)	Wasser	N-Wald		L-Wald
SG	81	0	0	4	11	0	0	0	0	0	0	0	96
WW	30	371	2	50	33	14	27	0	6	0	0	0	533
Mais	8	0	38	0	3	9	6	0	30	0	0	0	94
GL	0	36	0	262	27	0	8	0	0	0	0	0	333
Hafer	0	0	0	37	105	0	4	0	0	0	0	0	146
WG	0	21	0	24	0	103	20	0	0	0	0	0	168
Raps	20	46	0	12	0	0	82	0	0	0	0	0	160
Versieg1	0	0	0	0	0	0	0	31	0	0	0	0	31
Versieg2 (VK)	0	0	7	8	0	0	8	57	31	0	0	0	111
Wasser	0	0	0	0	0	0	0	0	0	25	0	0	25
N-Wald	0	0	0	0	0	0	0	0	0	0	105	60	165
L-Wald	0	0	0	28	0	0	0	0	0	0	0	144	172
unklass.	22	0	0	0	0	0	0	15	0	0	0	0	37
Summe	161	474	47	425	179	126	155	103	67	25	105	204	2071
Accuracy													
Producer	0,84	0,70	0,40	0,79	0,72	0,61	0,51	1,00	0,28	1,00	0,64	0,84	
User	0,50	0,78	0,81	0,62	0,59	0,82	0,53	0,30	0,46	1,00	1,00	0,71	
Overall Accuracy	0,67												
Overall Kappa	0,62												

Abkürzungen:
 SG...Sommergerste,
 WW...Winterweizen,
 Kart...Kartoffel,
 ZR...Zuckerrübe,
 WR...Winterroggen,
 Tab...Tabak,
 GL...Grünland,
 L-Wald...Laubwald,
 N-Wald...Nadelwald,
 Versieg1...Versiegelungsflächen
 ohne Verkehrswee,
 Versieg2...Versiegelungsflächen
 mit Verkehrswegen,
 VK...Verkehrswege

Tabelle A 9: Zeiträume für die Akkumulation der NDVI-Werte

Periode	Von Datum/Jul. Tag (JD) /phänologischer Phase	Bis Datum/Jul. Tag (JD) /phänologischer Phase	Anzahl Tage
Kal1	10.04. JD 100	17.07 JD 198	98
Kal2 (Mai)	1.05. JD 121	31.05. JD 151	30
Kal3 (Juni)	01.06. JD 152	30.06 JD 181	29
Kal4 (Juli)	01.07. JD 182	31.07. JD 212	30
GDD1	Schossen (SCH)	Ährenschieben (ÄS)	ca. 37 (RLP) ca. 22 (BW)
GDD2	Ährenschieben (ÄS)	Gelbreife (GR)	ca. 27 (RLP) ca. 47 (BW)
GDD3 ¹ :	ÄS minus 1/3 des Abstandes zu SCH	ÄS plus 2/3 des Abstandes zur GR	ca. 30 (RLP) ca. 38 (BW)
GDD4	Schossen (SCH)	Gelbreife (GR)	ca. 64 (RLP) ca. 69 (BW)

¹) Periode der erwarteten maximalen photosynthetischen Aktivität

Tabelle A 10: Bedingungen der Ableitung der Bodenwasserklassen aus regionaler Bodenkarte BW (BÜK200)

BÜK-Klasse	FK	FK [mm]	Zugewiesene Bd.wasserklasse	Zugewiesene Beschreibung
1	sehr gering	30 – 130	1	Leichter Boden
2	sehr gering bis gering	30 – 260	1	Leichter Boden
3	Sehr gering bis mittel	30 – 390	1	Leichter Boden
4	gering	130 – 260	1	Leichter Boden
5	Gering bis mittel	130 – 390	2	Mittelschwerer Boden
6	Mittel	260 – 390	2	Mittelschwerer Boden
7	Mittel bis hoch	260 – 520	2	Mittelschwerer Boden
8	Hoch	390 – 520	3	Schwerer Boden
9	Hoch bis sehr hoch	390 – 650	3	Schwerer Boden
10	Sehr hoch	520 – 650	3	Schwerer Boden
11	Stark wechselnd		0	(wurde anhand der Bodenart zugewiesen)

Tabelle A 11: Bedingungen der Ableitung der Bodenwasserklassen aus regionaler Bodenkarte BW (BÜK200) nach Bodenart

Substrat und Gründigkeit	BÜK- Code	BÜK-Beschreibung	Zugewiesene Beschreibung	Zugewiesene Bodenwasser klasse
Skelettfreie bis -arme, meist tiefgründige Böden	101	Sand	Leichter Boden	1
	102	Lehmsand	Leichter Boden	1
	103	Lehmsand im Wechsel mit Lehm	Leichter Boden	1
	104	Schluff	Mittelschwerer Boden	2
	105	Schluff im Wechsel mit Lehm	Mittelschwerer Boden	2
	106	Lehm	Mittelschwerer Boden	2
	107	Lehm im Wechsel mit Lehm über Ton	Mittelschwerer Boden	2
	108	Lehm über Ton	Mittelschwerer Boden	2
	109	Ton im Wechsel mit Lehm über Ton	Schwerer Boden	3
	110	Ton	Schwerer Boden	3
	111	Torf im Wechsel mit Sand und Lehm	Schwerer Boden	3
	112	Torf	Schwerer Boden	3
Skeletthaltige, meist mittel- bis tiefgründige Böden	201	Lehmsand	Leichter Boden	1
	202	Lehmsand im Wechsel mit Lehm	Leichter Boden	1
	203	Lehmsand im Wechsel mit Lehm über Ton	Leichter Boden	1
	204	Lehmsand über Lehm oder Ton	Leichter Boden	1
	205	Schluff im Wechsel mit Lehm	Mittelschwerer Boden	2
	206	Lehm	Mittelschwerer Boden	2
	207	Lehm im Wechsel mit Lehm über Ton	Mittelschwerer Boden	2
	208	Lehm über Ton	Mittelschwerer Boden	2
	209	Ton im Wechsel mit Lehm über Ton	Schwerer Boden	3
	210	Ton	Schwerer Boden	3
211	Torf im Wechsel mit Sand und Lehm	Schwerer Boden	3	
Skelettreiche, meist flach- bis mittelgründige Böden	301	Sand	Leichter Boden	1
	302	Lehmsand, Schluff und Lehm	Leichter Boden	1
	303	Lehm und Ton	Mittelschwerer Boden	2
Stark wechselnde Skelettführung und Gründigkeit	401	Lehm und Ton	Mittelschwerer Boden	2

Tabelle A 12: Bedingungen der Ableitung der Bodenwasserklassen aus regionalen Bodenkarte RLP

Bedingung	Zugewiesene Beschreibung	Zugewiesene Bodenwasserklasse
nFK < 120	Leichter Boden	1
120 < nFK < 170	Mittelschwerer Boden	2
nFK > 170	Schwerer Boden	3

Tabelle A 13: Nutzbare Feldkapazität [mm] der vom DWD für die Berechnung der tatsächlichen Evapotranspiration (ETa) zugrundegelegten Bodenarten

Bodenart	Nutzbare Feldkapazität [mm]
Sand	30
Lehmiger Sand	45
sandiger Lehm	60
Lehm	75

Tabelle A 14: Monatliche bzw. jährliche relative Umrechnungsfaktoren für die tatsächliche Evapotranspiration (ETa) von der Bodenart „lehmiger Sand“ auf andere Bodenarten

	J	F	M	A	M	J	J	A	S	O	N	D	Jahr
Sand	1,000	1,000	0,967	0,909	0,913	0,928	0,915	0,938	0,915	0,933	1,000	1,000	0,933
Sandiger Lehm	1,000	1,000	1,033	1,036	1,058	1,058	1,070	1,047	1,064	1,000	1,000	1,000	1,045
Lehm	1,000	1,000	1,033	1,073	1,101	1,101	1,127	1,078	1,085	1,033	1,000	1,000	1,077

Tabelle A 15: Prognosefehler als prozentuale Abweichung von prognostiziertem zu berichtetem Sommergerstenertrag des einfachen und erweiterten Ertragsprognosemodells der Jahre 1995 – 2002.

Land- kreis	Prognose- jahr	einfaches Ertragsprognosemodell								erweitert
		Kal1	Kal2	Kal3	Kal4	GDD1	GDD2	GDD3	GDD4	GDD2
		10.4.-17.7.	Mai	Juni	Juli	SCH - ÄS	ÄS - GR	MPA *	SCH - GR	ÄS - GR
Germ	1995	-24,6	-12,9	-33,6	8,9	5,8	-12,7	-5,3	-7,4	
Süw		-1,2	3,2	10,3	23,5	19,6	4,5	1,0	12,8	4,0
Fds		29,7	23,3	21,6	19,0	17,2	4,7	17,1	4,6	4,3
Rott		36,9	34,4	31,8	13,1	26,7	-22,3	3,4	15,3	-24,0
Tutt		-11,5	-0,5	14,3	13,3	25,5	3,3	3,9	3,2	3,1
Zak		15,5	18,6	4,4	21,8	28,4	18,0	20,6	15,2	
Germ	1996	-13,2	-14,7	-10,8	-17,7	-15,9	-5,8	-10,9	-11,6	
Süw		-7,1	-9,8	-5,0	-11,5	-11,2	-4,5	-2,6	-7,6	-3,4
Fds		-12,4	-12,3	-10,8	-12,3	-12,3	-10,3	-10,7	-10,3	-7,3
Rott		-14,1	-13,8	-12,0	-5,4	-18,9	-8,6	-6,8	-13,3	-7,9
Tutt		-7,4	-6,1	-7,2	-1,5	-7,2	-0,3	-2,1	-4,8	-0,3
Zak		-11,8	-12,2	-7,6	-4,4	-9,9	-3,1	-4,1	-2,3	
Germ	1997	-2,1	-2,8	-1,8	-7,7	-5,7	3,2	-7,0	6,9	
Süw		5,7	3,4	4,0	-0,8	0,8	16,9	1,1	16,5	14,6
Fds		-4,0	-4,8	-6,1	-6,3	-7,3	2,0	-1,3	-0,1	1,5
Rott		-3,7	-4,0	-7,1	1,9	-3,8	-0,4	-3,9	0,3	-1,2
Tutt		-2,3	-0,9	-13,4	2,1	-2,3	1,2	2,0	-2,0	1,2
Zak		4,5	3,1	-1,5	5,4	-0,6	9,3	8,9	10,0	
Germ	1998	-3,7	-0,5	-5,8	-6,3	-4,8	-3,6	-3,0	-0,4	
Süw		-9,7	-4,5	-15,5	-11,0	-10,8	-11,4	-6,4	-10,5	-13,4
Fds		0,6	-0,1	0,8	-1,3	-1,1	5,9	3,7	4,4	4,0
Rott		-3,9	-5,2	-3,6	-0,3	-5,0	-2,2	-7,0	-3,0	-3,9
Tutt		-7,9	-11,7	-8,3	-4,5	-12,6	-7,1	-6,7	-6,2	-7,2
Zak		-5,6	-7,7	-5,5	-3,9	-3,4	-3,6	-3,4	-1,1	
Germ	1999	-7,7	-8,3	-9,9	-24,5	-12,3	-3,0	-14,3	-9,4	
Süw		-6,0	-7,8	-8,4	-26,9	-11,5	-7,0	-4,0	-9,7	-7,1
Fds		16,8	16,6	15,9	16,1	17,4	9,1	19,5	8,4	8,4
Rott		14,7	14,2	14,2	-14,6	11,6	15,6	18,3	12,0	15,1
Tutt		10,5	9,2	12,3	-19,7	11,6	-1,5	14,1	-1,7	-1,6
Zak		12,0	10,5	9,1	-16,8	18,2	-14,8	11,4	-7,0	
Germ	2000	3,2	2,7	2,8	-0,1	-0,8	-9,1	-1,2	-5,5	
Süw		6,7	7,3	3,4	0,9	-0,1	-1,4	1,8	-0,8	-2,1
Fds		-2,7	-2,0	-2,9	-6,0	-5,5	0,4	-7,4	0,2	5,2
Rott		-1,3	-1,0	-1,5	-4,0	-2,4	-2,2	3,8	0,1	-3,7
Tutt		3,4	3,5	3,6	-2,3	-6,5	7,8	0,7	10,6	7,8
Zak		-2,5	-0,2	-3,1	-10,9	-13,4	-6,5	-14,4	-8,0	
Germ	2001	13,3	12,7	15,2	19,8	27,4	19,5	28,2	9,7	
Süw		2,1	-0,7	7,9	11,8	19,2	7,1	15,2	1,9	5,1
Fds		-8,7	-10,9	-9,9	-6,4	-6,6	-11,1	-8,0	-10,2	-12,3
Rott		-8,5	-8,7	-8,3	-5,3	-7,2	-6,5	-5,5	-8,0	-6,9
Tutt		5,3	5,6	7,7	9,5	5,1	4,6	4,2	9,6	4,5
Zak		-3,0	-2,8	-1,6	3,5	-9,1	2,4	1,5	-1,3	
Germ	2002	29,9	30,3	28,0	28,5	37,6	14,0	22,0	27,6	
Süw		13,3	14,2	14,5	13,4	18,3	7,9	-6,4	14,1	6,7
Fds		11,1	10,7	14,0	70,4	27,5	6,6	4,9	10,9	6,3
Rott		16,8	18,4	19,9	11,9	17,0	9,2	3,9	14,3	7,0
Tutt		3,8	4,5	4,3	-2,4	-7,2	-4,0	-10,5	-3,3	-4,1
Zak		7,4	9,4	13,2	5,1	3,2	0,7	-5,7	1,7	

Danksagung

Ich möchte mich bei Herrn Prof. Dr. W. Kühbauch für die Überlassung dieses Themas, die wissenschaftliche Betreuung und das erhaltene Vertrauen für die Bearbeitung dieses Vorhabens bedanken. Obwohl während des geförderten Projektzeitraumes bisweilen Schwierigkeiten auftraten, kam mir seinerseits stets uneingeschränkte Unterstützung zu. Ein Dank gilt allen Mitarbeitern des Instituts für Pflanzenbau, besonders den Kollegen Doktoranden.

Besonderen Anteil an dieser Arbeit haben die ausgezeichneten Arbeitsmöglichkeiten, die sich am Zentrum für Fernerkundung (ZFL) der Universität Bonn ergeben haben. Herrn Prof. Dr. G. Menz danke ich als Sprecher des Zentrums sowie für die Übernahme des Co-Referats.

Einen besonderen Dank möchte ich Herrn Dr. Matthias Braun, dem Leiter des ZFL, sowie den Mitarbeitern am ZFL aussprechen, die mir durch zahlreiche konstruktive Gespräche wertvolle Anregungen und Hilfestellungen während dieser Arbeit gegeben haben. Die sehr angenehme Arbeitsatmosphäre hat die nötigen Motivationsschübe hervorgebracht.

Meiner Familie und meinen Freunden danke ich für Ihre Hilfsbereitschaft und Ihre geistige Unterstützung, die zum Gelingen dieser Arbeit beigetragen hat.

Der geförderte Teil dieser Arbeit wurde unterstützt von BMBF bzw. DLR (DLR-50EE0106 - "Yield & Quality").

Ein Dank gilt den beteiligten Landwirten für die Bereitstellung von Versuchsfeldern.