

## Klassifikation von Getreideflächen mit hyperspektralen Bilddaten des HyMap-Sensors

THOMAS UDELHOVEN, Trier, PATRICK HOSTERT, Berlin, THOMAS JARMER & JOACHIM HILL, Trier

**Keywords:** remote sensing, GIS, HyMap, hyperspectral data, landuse, artificial neural networks (ANN)

**Zusammenfassung:** Für ein Testgebiet im Hunsrück (SW-Deutschland) wurde eine überwachte pixelbasierte Klassifikation von Getreideflächen mit hyperspektralen Bilddaten des HyMap-Sensors durchgeführt. Eine Grobklassifikation trennte Getreideschläge von sonstigen Landnutzungsflächen, wohingegen eine Detailklassifikation die Getreideklasse weiter in Hafer, Roggen, Sommer- und Wintergerste sowie Weizen differenzierte. Wichtige Vorverarbeitungsschritte beinhalteten die parametrische Geokodierung und radiometrische Korrektur der Bilddaten. Als Klassifikationsalgorithmus wurde ein künstliches neuronales Netz (artificial neural network, ANN) mit resilient propagation (Rprop) als Lernalgorithmus verwendet. Eine aktuelle terrestrische Landnutzungserhebung unter Verwendung von Katasterinformationen stellte die Referenz für die Klassifikation dar. Die Anwendung des trainierten ANN auf einen Testdatensatz erbrachte eine gute Differenzierung des Getreideanbaus aus dem monotonalen Datensatz.

**Summary:** *Classification of crop areas using hyperspectral data from the HyMap-sensor.* A modular, pixel based, and supervised classification of crops was carried out with hyperspectral data from the HyMap-sensor for a test site in the Hunsrück mountains (SW-Germany). A pre-classification was employed for the differentiation of crop areas from non-crop areas, whereas the separability of wheat, oat, rye, winter barley, and summer barley was addressed in a sub-classification. Important pre-processing steps included a parametric geocoding approach and a radiometric correction. An artificial neural network (ANN) with the resilient backpropagation learning algorithm (Rprop) was applied for the actual classification. Cadastral information was combined with up-to-date land cover mapping to yield a reliable database for evaluation purposes. The transfer of the trained ANN to an independent test data set resulted in a reliable separation of the five different crops even from a mono-temporal data set.

### 1 Einleitung

Mit spektral hochauflösenden Fernerkundungssensoren können umweltbezogene Messgrößen auf verschiedenen Skalenebenen qualitativ und quantitativ abgeleitet werden. Bei der Klassifizierung von vegetationsbestandenen Flächen besteht jedoch häufig das Problem einer hohen Variabilität der Spektralsignaturen innerhalb einer Klasse. Landnutzungsklassifikationen lassen sich über multitemporale Auswertestrategien häufig durch die Ausnutzung von Unterschieden im phänologischen Verlauf un-

terschiedlicher Vegetationstypen verbessern. Bei der Verwendung flugzeuggestützter hyperspektraler Aufnahmesysteme, wie dem HyMap-Sensor, sind der Verfügbarkeit multitemporalen Bilddaten jedoch aus operativen, zeitlichen und monetären Gründen häufig Grenzen gesetzt. In dieser Studie wird die Differenzierbarkeit des Getreideanbaus in einem Untersuchungsgebiet im Hunsrück aus monotonalen HyMap-Bilddaten untersucht. In einer früheren Studie, die auf dem identischen Bilddatensatz beruht, wurde festgestellt, dass Hafer, Roggen, Sommergerste, Wintergerste und Weizen trotz

erheblicher Intra-Klassen-Varianzen interpretierbare spektrale Unterschiede aufweisen (HOSTERT et al. 2001). In der vorliegenden Untersuchung wird die Trennbarkeit dieser Getreidearten mit einem überwachten Klassifikationsansatz überprüft.

## 2 Untersuchungsgebiet

Das Untersuchungsgebiet befindet sich im Hunsrück etwa 10 km südlich der Stadt Trier. Es ist stark reliefiert und wird von Gesteinen des Unterdevons dominiert. Je nach Geländelage herrschen flach- oder tiefgründige Böden vom Typ des Rankers oder der sauren Braunerde vor. Diese meist flachgründigen Böden verfügen über einen hohen Sklettanteil und weisen mittlere Ackerzahlen von nur 35 auf. Im betrachteten Bildausschnitt liegen überwiegend Getreideanbauflächen, welche nur vereinzelt durch Ölsaaten abgelöst werden. Aufgrund der oftmals nur geringen bis mittleren Erträge ist in den Bilddaten mit spektralen Mischsignaturen der Vegetation mit dem Boden zu rechnen. Entlang der Talauen befindet sich bei einer ausreichenden Breite Grünland, ebenso wie auf den nicht mit Wald bestandenen Quellmulden der Plateauflächen. Der betrachtete Ausschnitt kann als repräsentativ für weite Bereiche der umgebenden Anbauflächen angenommen werden.

## 3 Material

Am 10. Juni 1999 wurden während eines Überflugs mehrere Aufnahmen mit dem HyMap-Sensor von landwirtschaftlich benutzten Flächen in der Region Trier akquiriert. Der HyMap-Sensor erfasst mit vier Spektrometern einen Wellenlängenbereich zwischen 400 nm und 2.500 nm in 128 Kanälen. Die spektrale Bandbreite der Kanäle variiert zwischen 13,7 nm und 24,3 nm. Das signal-to-noise Verhältnis ist nach Angaben der Deutschen Gesellschaft für Luft- und Raumfahrt für alle Kanäle größer als 500 : 1 (DLR 2000). Eine radiometrische Qualitätsüberprüfung ergab jedoch, dass einige Kanäle durch striping (Kanäle 1, 2), sichtbares Rauschen (Kanäle 65, 67, 68, 97) und durch ein

graduell abnehmendes signal-to-noise Verhältnis (Kanäle 124 bis 128) fehlerbehaftet waren. Der mitgelieferte Hilfsdatenstrom umfasste die geometrische Position des Sensors, die mit vier differentiellen GPS verfolgt wurde, Fluglageparameter von einem mitgeführten IGI-System sowie radiometrische Kalibrierungsparameter.

Als Referenz für die durchzuführende Landnutzungsklassifikation stand eine terrestrische, parzellenbezogene Landnutzungserhebung zur Verfügung (Abb. 1), die von dem Lehrstuhl für Biogeographie an der Universität Trier während des späten Frühjahrs und Frühsommers 1999 durchgeführt wurde. Die Daten wurden zur Überlagerung mit den orthoentzerrten HyMap-Daten in einem GIS (ArcView 3.2) vorgehalten. Um störende Mischpixel an den Parzellengrenzen zu eliminieren, wurden die Vektoren der Landnutzungsklassen gepuffert (20 m) und jeweils nur die inneren Polygone für die weiteren Auswertungen verwendet.

Zum Überflugzeitpunkt erfolgten Referenzmessungen (Grünflächen, Böden, Asphalt und Sportplätze) mit einem ASD FieldSpec II-Spektrometriemeter im Wellenlängenbereich von 400 nm bis 2500 nm. Für die Orthoentzerrung der Bilddaten wurden 30 Bodenkontrollpunkte mit einem GPS (Trimble Pathfinder ProXR) differentiell eingemessen. Die geometrische und radiometrische Weiterverarbeitung erfolgte zusammen mit einem auf 20 m Auflösung interpolierten ATKIS-DGM des Landesvermessungsamtes Rheinland-Pfalz.

## 4 Datenvorverarbeitung und Methoden

Die parametrisch-geometrische Korrektur der Bilddaten erfolgte mit der Software Parge<sup>TM</sup> (SCHLÄPFER & RICHTER 2002) unter Einbeziehung des digitalen Höhenmodells, der erhobenen Bodenkontrollpunkte, sowie der zeilensynchron verfügbaren Positionsparameter des Sensors. Die Überlagerung der korrigierten Bilddaten mit den vektorisierten großmaßstablichen Katasterdaten (Abb. 1) belegt die hohe Präzision der geometrischen Korrektur. Die Bilddaten wur-

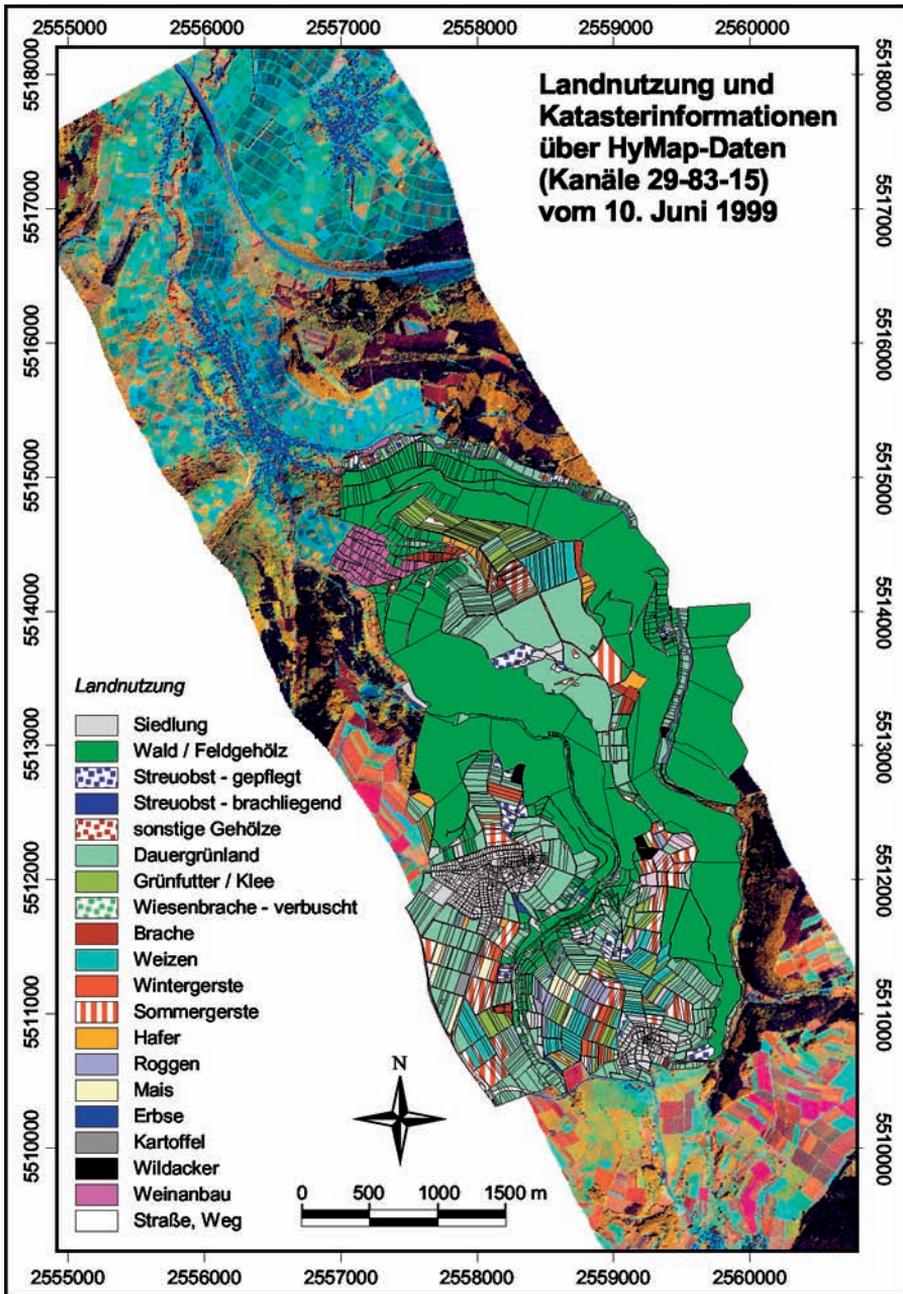


Abb. 1: Landnutzung über HyMap-Daten im Untersuchungsgebiet.

den anschließend mit den erhobenen Referenztargets und dem digitalen Höhenmodell radiometrisch korrigiert. Dies schloss eine across-track-Beleuchtungskorrektur, die Kompensation der zum Überflugzeitpunkt herrschenden atmosphärischen Bedingungen, eine topographische Beleuchtungskorrektur sowie eine „in-flight“ Kalibration des HyMap-Aufnahmesystems ein (HILL & MEHL, diese Ausgabe).

Zum Überflugzeitpunkt am 10. Juni dominierten im Anbau Weizen, Roggen, Hafer, Sommergerste und Wintergerste, deren spektrale Differenzierung den Schwerpunkt der vorliegenden Untersuchung darstellt. Mit einem zweistufigen neuronalen Klassifikationsansatz wurden zunächst Getreidepixel von nicht-Getreidepixeln getrennt. In der sich anschließenden Detailklassifikation erfolgte die Differenzierung der fünf Getreidearten.

Für die Erstellung und Validierung des Klassifikationsmodells wurden die Getreideschläge mit bekannter Nutzung in ein Training-, Monitoring- und ein Testset aufgeteilt. Um eine ausreichende Repräsentativität der drei Datensätze bei der Aufteilung zu gewährleisten, erfolgte eine Voranalyse der Getreideschläge mit dem unüberwachten Isodata-Algorithmus. Bei der Zuteilung der Parzellen wurde darauf geachtet, dass Schläge aus allen Clustern in den drei Datensätzen vertreten waren. Für die Grobklassifikation wurden diese Datensätze zusätzlich durch Trainingsgebiete erweitert, die sonstige Landnutzung repräsentierten. Diese sehr heterogene Gruppe umfasst u. a. Siedlungs-, Wasser- und Waldflächen sowie Hackfrucht- und Futterbau und Sonderkulturen. Für das Training der neuronalen Netze (ANN) war es ausreichend, nur ein Drittel der verfügbaren Trainingspixel, verteilt über alle Schläge des Trainingssets, zu verwenden.

Zur Datenkomprimierung der Pixelspektren wurde die Hauptkomponentenanalyse (PCA) eingesetzt. Um die Unabhängigkeit der drei Datensätze zu wahren und gleichzeitig eine optimale Differenzierung der Getreidearten zu erhalten, erfolgte keine globale PCA über alle Bilddaten. Vielmehr wur-

den selektiv die Trainings-Getreidespektren PC-transformiert. Die Spektren des Validierungs- und Testdatensatzes sowie die nicht-Getreide-Spektren wurden anschließend unter Verwendung der berechneten Eigenvektoren in den PC-transformierten Datenraum des Trainingssets überführt.

Für das überwachte Training eines dreistufigen ANN mit sigmoidalen Transferfunktionen wurde der Resilient propagation (Rprop-) Algorithmus verwendet (RIEDMILLER & BRAUN 1993). Die Zahl der Ausgabeneuronen ergab sich aus der Zahl der zu trennenden Klassen, d.h. zwei für die Grobklassifikation und fünf zur Detailklassifikation. Das ANN-Training erfolgte mit dem Trainingsdatensatz. Die geeignete Zahl an Inputneuronen (= Zahl der verwendeten Hauptkomponenten) und der verdeckten Neuronen wurde dagegen iterativ durch Minimierung des „Mean Squared Error“ (MSE) des Monitoringdatensatzes („Validierungsdatensatz“) durch systematische Variation der Neuronenzahl ermittelt.

Die Interpretation der Aktivierung der Ausgabeneuronen erfolgte nach dem winner-takes-all-Prinzip, wobei neben dem Ausgabeneuron mit der höchsten Aktivierung (= Gewinnerklasse) auch der Abstand zum Ausgabeneuron mit der zweithöchsten Aktivierung berücksichtigt wurde. Bei Verwendung sigmoidaler Transferfunktionen ist die Aktivierung der Neuronen dabei auf den Wertebereich [0,1] beschränkt. Die Definition einer Rückweisungsklasse erfolgte durch unterschiedliche Festlegung von Aktivierungsschwellwerten der Ausgabeneuronen, wobei entweder die Herstellergenauigkeit („error of omission“) oder die Nutzergenauigkeit („error of commission“) des Monitoringdatensatzes klassenspezifisch maximiert wurde. Die so gefundenen Schwellwerte wurden nach Anwendung der trainierten ANNs zur Post-Klassifizierung des Testdatensatzes verwendet.

## 5 Ergebnisse

Die Abb. 2 zeigt die Mittelwertsspektren der fünf zu klassifizierenden Getreideklassen mit den dazugehörigen Standardabweichungen.

chungen. Im Mittel sind die Vegetationsklassen sehr ähnlich; eine Trennung scheint am ehesten im nahen Infrarot (NIR) möglich zu sein. Weizen und Wintergerste lassen sich dort gut von Hafer, Sommergerste und Roggen unterscheiden. Allerdings zeichnet sich das NIR-Plateau auch durch die größten spektralen Standardabweichungen aus. Die Roggenspektren weisen dort besonders große Variabilitäten auf, aber auch Hafer und Weizen zeigen hohe Variabilitäten. Spektrale Überschneidungen der Klassengrenzen sind daher unvermeidbar.

Bei der systematischen Festlegung der ANN-Architektur erwies sich ein ANN mit 24 Inputneuronen (= PCs) und vier verdeckten Neuronen (24-4-5 Architektur) am geeignetsten für die Trennung der fünf Getreideklassen. Für die Grobklassifikation ergab sich ein 3-5-2 ANN-Modell. Tab. 1 und Tab. 2 stellen die Ergebnisse der Klassifizierung dar, die eine gute Differenzierung zwischen den Getreideklassen erkennen lassen. In Tab. 1 sind die Hersteller- und Nutzergenauigkeiten für die Klassifikation ohne Rückweisungsklasse zusammengefasst. Da das „winner-takes-all“-Prinzip zur Festlegung der Gewinnerklasse in diesem Fall uneingeschränkt gilt, wurden dabei die höchsten Herstellergenauigkeiten erreicht. Die Tab. 2 gibt die Ergebnisse nach Maximieren der Nutzergenauigkeit durch das Einführen einer Rückweisungsklasse wieder.

Erwartungsgemäß sind die Klassifikationsgenauigkeiten für den Trainingsdatensatz am höchsten. Doch auch im Testdatensatz werden ohne Berücksichtigung einer Rückweisungsklasse Hersteller- und Nutzergenauigkeiten bei Sommergerste, Wintergerste, Weizen und sonstiger Nutzung meist Werte von über 90 % erreicht. Eine Ausnahme stellen die mit Roggen bestandenen Schläge dar, für deren Pixel nur eine mittlere Zuordnungsgenauigkeit erreicht werden konnte. Obwohl der Monitoringdatensatz an der Modellbildung indirekt beteiligt war, sind dessen optimierte Herstellergenauigkeiten, mit Ausnahme von Wintergerste, schlechter als diejenigen des Testdatensatzes.

Trotz klassenspezifischer Maximierung der Nutzergenauigkeiten verbessern sich diese im Testdatensatz mit Ausnahme von Hafer und Roggen nur geringfügig. Der damit verbundene Rückgang der Herstellergenauigkeiten ist jedoch auffallend groß. Im Monitoringset können die Nutzergenauigkeiten zwar deutlich gesteigert werden, aber dies hat ebenfalls zum Teil inakzeptabel große Rückweisungsklassen, d. h. geringe Herstellergenauigkeiten, zur Folge.

## 6 Diskussion

Die spektrale Varianz innerhalb der fünf Getreideklassen ist aufgrund unterschiedlicher biophysikalischer Parameter, die wiederum

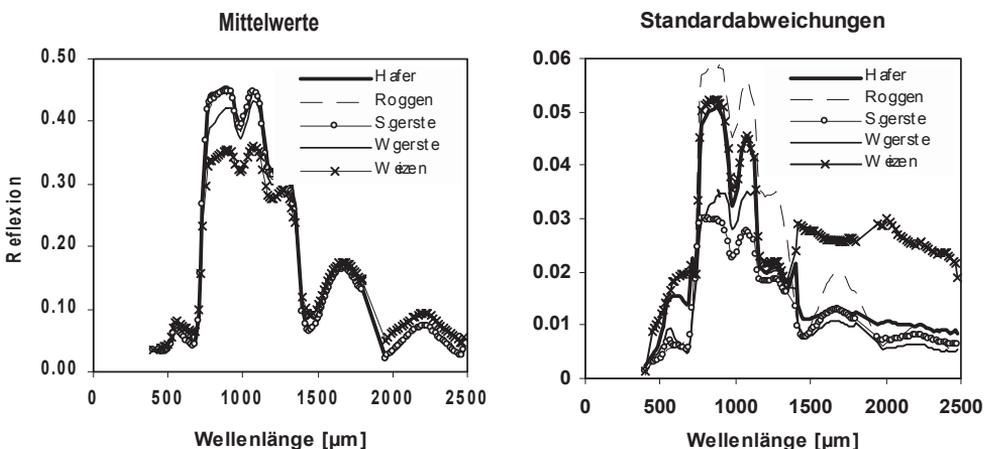


Abb. 2: Mittelwertsspektren und mittlere Standardabweichungen der Getreideklassen.

**Tab. 1:** Ergebnis der Getreideklassifikation aus HyMap-Daten ohne Rückweisungsklasse (Minimalaktivierung des Neurons der Gewinnerklasse: 0, Abstand zur Aktivierung der zweitbesten Klasse: 0). Die aufgeführten Werte für den Trainingsdatensatz ergaben sich nach Klassifikation des gesamten Trainingssets. Für das ANN-Training wurde nur jedes dritte Pixel (867 Pixel) aus diesem Set verwendet. Die angegebenen a-priori-Wahrscheinlichkeiten ergeben sich aus der Zusammensetzung der drei Datensätze und spiegeln daher nicht genau die Verteilung im Untersuchungsgebiet wider.

#### Trainingsdatensatz (4713 Pixel)

	A-priori	Hersteller Genauig-	Nutzer Genauig-
	prob.	keit	keit
Hafer	0.09	0.98	0.95
Roggen	0.06	0.92	0.90
S. gerste	0.26	0.97	0.92
W. gerste	0.09	0.99	0.99
Weizen	0.07	0.87	0.93
Sonst.			
Nutzung	0.43	0.95	0.98

#### Monitoringdatensatz (6012 Pixel)

	A-priori	Hersteller Genauig-	Nutzer Genauig-
	prob.	keit	keit
Hafer	0.03	0.75	0.88
Roggen	0.08	0.54	0.65
S. gerste	0.24	0.76	0.72
W. gerste	0.05	0.99	0.85
Weizen	0.21	0.46	0.94
Sonst.			
Nutzung	0.39	1.00	0.79

#### Testdatensatz (14150 Pixel)

	A-priori	Hersteller Genauig-	Nutzer Genauig-
	prob.	keit	keit
Hafer	0.07	0.75	0.76
Roggen	0.04	0.68	0.59
S. gerste	0.28	0.85	0.91
W. gerste	0.04	0.97	0.95
Weizen	0.25	0.92	0.92
Sonst.			
Nutzung	0.33	0.96	0.92

**Tab. 2:** Ergebnis der Getreideklassifikation mit HyMap-Daten mit klassenspezifischer Definition einer Rückweisungsklasse für den Monitoring- und Testdatensatz. Die winner-takes-all- (WTA-) Schwellwerte wurden durch Maximierung der Nutzergenauigkeit des Monitoringsets bestimmt.

#### Pixel der Monitoring-(Validierungs)-Schläge

Klasse	opt. WTA Grenzwert	opt. Dist. zum 2ten	Hersteller-genauigkeit	Nutzer-genauigkeit	RICHTIG	FALSCH	NICHT KLASS.
Hafer	0.90	0.90	0.50	1.00	88	3	84
Roggen	0.90	0.00	0.11	0.88	50	106	307
S.gerste	0.90	0.90	0.57	0.82	816	162	448
W.gerste	1.00	0.90	0.53	0.85	170	1	148
Weizen	0.90	0.00	0.29	0.99	372	312	608
Sonst.							
Nutzung	0.90	0.90	0.83	0.93	1935	0	402

#### Pixel der Test-Schläge (mit WTA-Schwellwerten aus dem Monitoringset)

Klasse	opt. WTA Grenzwert	opt. Dist. zum 2ten	Hersteller-genauigkeit	Nutzer-Genauigkeit	RICHTIG	FALSCH	NICHT KLASS.
Hafer	0.90	0.90	0.37	0.92	353	28	571
Roggen	0.90	0.00	0.41	0.86	217	86	230
S.gerste	0.90	0.90	0.54	0.98	2140	88	1711
W.gerste	1.00	0.90	0.68	1.00	393	4	185
Weizen	0.90	0.00	0.32	0.93	1120	67	2301
Sonst.							
Nutzung	0.90	0.90	0.63	0.97	2929	16	1711

standortabhängig sind, im Untersuchungsgebiet verhältnismäßig groß. Dafür verantwortlich sind Faktoren wie phänologischer Entwicklungszustand, Bestandsdichte und -höhe, Sichtbarkeit des Bodenhintergrundes, klimatische und pedologische Unterschiede. Diese Faktoren führen zu großen Intra-Klassenvariabilitäten (BARET & JAQUEMOUD 1994, GUYOT 1990). Die großen spektralen Standardabweichungen auf dem NIR-Plateau bei Roggen und Hafer können wahrscheinlich auf unterschiedliche geoökologische Randbedingungen der Schläge, die in Höhenlagen zwischen 130 m bis 350 m auftreten, zurückgeführt werden. Bei Wintergerste war zum Überflugtermin der Übergang von der photosynthetisch aktiven Phase zur Gelbreife bereits vollzogen, so dass eine gute Unterscheidung von den übrigen Getreideklassen möglich war. Die hohe Variabilität beim Weizen im Wellenlängenbereich des mittleren Infrarot ist wahrscheinlich ebenfalls durch Standortunterschiede, insbesondere durch eine unterschiedliche Wasserversorgung, zu erklären (GUYOT 1990). Insgesamt konnte jedoch eine gute Differenzierung zwischen den berücksichtigten Getreidearten erreicht werden.

Der im Vergleich zum Testset größere Klassifikationsfehler im Monitoringset zeigt, dass dieser die Varianz des Trainingsdatensatzes schlechter abbildet als der etwa doppelt so große Testdatensatz. Nicht völlig ausgeschlossen werden können auch vereinzelte Kartierfehler bei der terrestrischen Landnutzungserhebung. Das Ergebnis bestätigt die Bedeutung des Designs der Trainings- und Monitoringsets, die gleichermaßen für ein Untersuchungsgebiet repräsentativ sein sollten. Wenn, wie im vorliegenden Fall, ein Monitoringset an der Modellfindung beteiligt ist, stellt der Fehler eines unabhängigen Testdatensatzes ein besseres Maß zur Beschreibung der Generalisierereigenschaften des ANN dar (DESPAGNE & MASSART 1998).

Die große Zahl der für eine gute Klassentrennung benötigten Hauptkomponenten überrascht hinsichtlich der rasch sinkenden Eigenwerte, die bereits nach der siebten Hauptkomponente Beträge  $< 1$  aufwiesen.

Die wesentlichen Kriterien der PCA bilden die Kovarianzmaximierung und die Orthogonalität der Faktorwerte, nicht aber die Gruppenzugehörigkeit. Zudem werden bei der PCA nicht-lineare Abhängigkeiten in der X-Matrix unter Annahme eines linearen Zusammenhangs häufig nur auf hintere Hauptkomponenten projiziert. Obwohl nachrangige Hauptkomponenten nur wenig erklärte Varianz des X-Datenraumes auf sich vereinigen, leisten sie im Einzelfall einen signifikanten Beitrag zur Klassentrennung. Die Festlegung der Zahl signifikanter Hauptkomponenten ausschließlich durch ein Eigenwertkriterium ist daher häufig nicht die optimale Lösung (MALINOWSKI & HOWERY 1980, BARROS & RUTLEDGE 1998, DESPAGNE & MASSART 1998).

Die Hersteller- und Nutzergenauigkeit lassen sich über einen weiten Bereich durch angepasste Rückweisungsschwellen variieren. Bei einem modularen Modell ist dabei zu berücksichtigen, dass Veränderungen der Schwellwerte in der Grobklassifikation auch Veränderungen der Klassifikationsgenauigkeiten in den untergeordneten Modellen zur Folge haben. Bei der Grobklassifikation ist es sinnvoll, die Nutzergenauigkeit zu maximieren, um Fremdspektren wirksam herauszufiltern, die anderenfalls in den Untermodellen beim Einsatz von ANNs zu schwer vorhersagbaren Ergebnissen führen können. Hohe Nutzergenauigkeiten müssen jedoch bei spektralen Überschneidungen der Klassen mit zum Teil inakzeptabel großen Rückweisungsklassen erkauft werden.

## 7 Zusammenfassung

Die vorliegende Untersuchung belegt eine erfolgreiche spektrale Differenzierung von Getreide aus mono-temporalen hyperspektralen Bilddaten des HyMap-Sensors trotz erheblicher Standortunterschiede zwischen den Schlägen. Voraussetzungen dafür waren das Erfassen eines geeigneten phänologischen Zustands und eine ausreichend große Zahl an Referenzen für die überwachte Klassifikation. Wegen der deutlichen Reliefunterschiede im Untersuchungsgebiet war

eine physikalisch basierte geometrische und radiometrische Datenvorverarbeitung notwendig. Der verwendete modulare Klassifikationsansatz birgt den Vorteil der Erweiterbarkeit, denn eine Klasse lässt sich durch weitere Sub-ANNs weiter differenzieren, ohne die Kalibrierung der übergeordneten ANNs wiederholen zu müssen. So könnte die bei der Grobklassifikation definierte Klasse „sonstige Nutzung“ ohne Einfluss auf die Trennung der bereits berücksichtigten Getreidearten weiter differenziert werden.

### Danksagung

Diese Studie wurde mit Mitteln aus dem Sonderforschungsbereich 522 „Umwelt und Region“ an der Universität Trier gefördert. Das Autorenteam bedankt sich für die Unterstützung der Abteilung Biogeographie, FB VI, Universität Trier, für die zur Verfügung gestellte Referenzkartierung. Weiterhin sei allen studentischen Mitarbeitern gedankt, welche an der Datenaufbereitung beteiligt waren, insbesondere SAMUEL BÄRISCH.

### Literatur

- BARET, F. & JACQUEMOUD, S., 1994: Modeling canopy spectral properties to retrieve biophysical and biochemical characteristics. – In: HILL, J. & MÉGIER, J. (eds.): *Imaging spectrometry – a tool for environment observations*. – 147–167, Kluwer, Amsterdam.
- BARROS, A. S. & RUTLEDGE, D. N., 1998: Genetic algorithm applied to the selection of principal components. – *Chemometrics and Intelligent Laboratory Systems*, **40**: 65–81.
- DESPAGNE, F. & MASSART, D. L., 1998: Neural networks in multivariate calibration. – *The Analyst*, **123**: 157R–178R.
- GUYOT, G., 1990: Optical properties of vegetation canopies. – In: STEVEN, M. D. & CLARK, J. A. (eds.): *Applications of remote sensing in agriculture*. – 19–43, Butterworths, London.
- German Aerospace Centre (DLR), 2000: Information on the HyMap Hyperspectral Mapping System, [http://www.op.dlr.de/dais/hymap/hymap\\_men.htm](http://www.op.dlr.de/dais/hymap/hymap_men.htm) (21/11/2000).
- HILL, J. & MEHL, W., 2003: Geo- und radiometrische Aufbereitung multi- und hyperspektraler Daten zur Erzeugung langjähriger kalibrierter Zeitreihen. – *Photogrammetrie – Fernerkundung – Geoinformation 2003* (1): 7–13. (diese Ausgabe)
- HOSTERT, P., JARMER, T., UDELHOVEN, T. & HILL, J., 2001: Sensitivity analysis of HyMap data for agricultural applications. – *Second EARSeL Workshop on Imaging Spectroscopy*, Enschede, 2000, 6p.
- MALINOWSKI, E. H. & HOWERY, D. G., 1980: *Factor Analysis in Chemistry*. – John Wiley & Sons, New York.
- RIEDMILLER, M. & BRAUN, H., 1993: A direct adaptive method for faster backpropagation learning: The RPROP algorithm. – In: RUSPINI, H. (ed.): *Proceedings of the IEEE International Conference on Neural Networks (ICNN)* (San Francisco), 586–591.
- SCHLÄPFER, D. & RICHTER, R., 2002: Geosatmospheric Processing of Airborne Imaging Spectrometry Data Part 1: Parametric Orthorectification. – *International Journal of Remote Sensing*, **23**: 2609–2630.

#### Anschriften der Autoren:

Dr. rer.nat. THOMAS UDELHOVEN, Universität Trier, Abt. Fernerkundung, Behringstrasse, D-54286 Trier, Tel.: +49-651-201-4594, Fax: +49-651-201-3815, e-mail: udelhove@uni-trier.de

Dr. rer.nat. PATRICK HOSTERT, Juniorprofessor für Fernerkundung und Geoinformatik, Humboldt-Universität zu Berlin, Mathematisch-Naturwissenschaftliche Fakultät II, Geographisches Institut, Abt. Geoinformatik/Kartographie, Unter den Linden 6, D-10099 Berlin, Tel.: +49 30 2093-6805, Fax: +49 30 2093-6835 e-mail: patrick.hostert@geo.hu-berlin.de

Dipl.-Geogr. THOMAS JARMER, Universität Trier, Abt. Fernerkundung, Behringstrasse, D-54286 Trier, Tel.: +49-651-201-4605, Fax: +49-651-201-3815, e-mail: jarmer@uni-trier.de

Prof. Dr. rer.nat. JOACHIM HILL, Universität Trier, Abt. Fernerkundung, Behringstrasse, D-54286 Trier, Tel.: +49-651-201-4591, Fax: +49-651-201-3815, e-mail: hillj@uni-trier.de

Manuskript eingereicht: November 2002  
Angenommen: November 2002