

Erfassung der Landnutzung und naturschutzrelevanter Flächen am Starnberger See und im Naturschutzgebiet Osterseen mit Hilfe von Hyperspektraldaten

KATHARINA DREXEL, Stephanskirchen

Keywords: remote sensing, land use seizing, nature protection, CASI, hyperspectral data, Maximum Likelihood, spectral indices

Zusammenfassung: Innerhalb des Forschungsprojekts AQUATIC wurde im September 1999 das im Alpenvorland gelegene Starnberger See- und Osterseengebiet mit einem CASI-Scanner befliegen. Dieser Hyperspektralscanner nimmt Wellenlängen von Blau bis NIR auf. Den Schwerpunkt vorliegender Arbeit bildete eine Maximum Likelihood-Klassifikation. Die Verifikation erfolgte anhand einer Confusion Matrix. Um eine Verbesserung des Klassifikationsergebnisses zu erzielen, wurden zusätzlich spektrale Indices unterschiedlicher Wellenlängen getestet.

Insgesamt ergaben sich 37 Landnutzungsclassen. Mit Abstand die besten Klassifikationsergebnisse entstanden für spektral relativ einheitliche Oberflächen wie Gewässer oder Ackerflächen. Auch verschiedene Typen von Feuchtgebietvegetation ließen sich gut differenzieren. Am wenigsten befriedigend funktionierte der Klassifikationsalgorithmus bei Wald (Ausnahme Fichten).

Von den spektralen Indices erzielten Simple Ratios weitaus die besten Resultate. Die verwendeten Wellenlängen der optimal geeigneten Indices lagen im NIR und im Rot, jedoch erzielte auch die Verwendung des Blau- anstatt eines Rotkanals teilweise eine Verbesserung der Klassifikation. Die unterschiedlichen Ergebnisse für diverse Landnutzungsformen sowie die Wirkung einzelner Vegetationsindices auf das Resultat werden diskutiert.

Summary: *Seizing the land use and nature protection-relevant surfaces at Lake Starnberg and in the nature reserve Osterseen by hyperspectral data.* Within the research project AQUATIC a flight above Lake Starnberg and the Osterseen area, situated in the Alpine foreland, was realized in September 1999 with a CASI scanner. This hyperspectral scanner takes up wavelengths of blue to NIR. The focus of that study consisted in a Maximum Likelihood classification. The verification was based on a confusion matrix. In order to obtain an improvement of the classification result, spectral indices of different wavelengths were additionally tested.

Altogether 37 land use classes resulted. Far the best classification results developed for spectrally relatively uniform surfaces such as water or areas of arable land. Also different types of humid area vegetation could be differentiated well. Few satisfying the classification algorithm worked with forest (excepted spruces).

From the spectral indices Simple Ratios obtained by far the best results. The used wavelengths of the most optimally suitable indices lay in the NIR and red, however also the use of blue instead of a red channel partly obtained an improvement of the classification. The different results for various land use forms as well as the effect of individual vegetation indices on the result are discussed.

1 Einleitung

Im September 1999 fand im Rahmen des Forschungsprojekts AQUATIC eine Befliegung von Starnberger See und Osterseengebiet mit einem CASI-Scanner (Compact

Airborne Spectrographic Imager) statt. Ziel dieses Projekts ist, verschiedene Methoden der computergestützten Auswertung von Fernerkundungsdaten zu testen, nachdem Arbeiten im Gebiet bisher nur auf visueller Interpretation von Schwarz-Weiß-, Color-

Tab. 1: CASI-Kanäle, mit denen die Auswertung durchgeführt wurde.

Kanal	Wellenlänge (Beginn des Kanals)	Breite in nm
1	489	11
2	500	12
3	522	12
4	556	11
5	567	11
6	578	11
7	624	12
8	636	12
9	681	12
10	693	11
11	704	12
12	716	12
13	727	12
14	739	12
15	750	12
16	773	12
17	830	13
18	853	13
19	899	14
20	922	14

und Infrarotaufnahmen beruht hatten (GROSSER, POHL & MELZER 1996).

Das AQUATIC-Projekt wurde durch die Limnologische Station Iffeldorf des Departments für Ökologie und durch den Lehrstuhl für Landnutzungsplanung und Naturschutz des Departments für Ökosystem- und Landschaftsmanagement der Technischen Universität München-Weihenstephan initiiert. Die Auswertung der CASI-Daten erfolgte als Teilbereich des Forschungsprojekts von Oktober 2001 bis Juli 2002 in Form rein Grauwert-basierter Klassifikationen. Die Bodenpixelgröße betrug $3\text{ m} \times 3\text{ m}$. Der CASI ist ein Hyperspektralscanner, d. h. er erfasst Reflexionen in vielen Spektralkanälen sehr geringer Bandbreite (s. Tab. 1).

Zunächst wurde eine Befliegung mit 44 Kanälen durchgeführt. Da ein solcher Datensatz einen enormen Bedarf an Speicherplatz und Rechenkapazität verlangt hätte, erfolgte für die Auswertung eine Reduzierung auf 20 Kanäle. Ausgesondert wurden redundante Kanäle (z. B. im Grünbereich) und die Kanäle im Blaubereich, die zu viel „noise“ aufwiesen.

Für die Klassifikationen wurde die Fernerkundungssoftware ENVI verwendet.

2 Untersuchungsgebiet

Das Gebiet um Starnberger See und Osterseen erstreckt sich auf 20 bis 55 km südlich von München. Als so genannte Eiszerfallslandschaft weist diese Gegend einen regen Wechsel zwischen größeren und kleineren Seen, Wäldern (knapp die Hälfte des Untersuchungsgebiets ist bewaldet) und Kulturland auf, das hauptsächlich aus Wiesen und Weiden besteht. Vor allem in Gewässernähe befinden sich zahlreiche Biotope: Hochmoorreste, Kalkflachmoore, die in der Regel als Streuwiesen genutzt werden, Verlandungszonen, Röhrichte und Großseggenriede. Die erfassten Parameter aus dem aquatischen und ufernahen terrestrischen Bereich sollen als Informationsebene zukünftiger Gewässerentwicklungs- und FFH-Managementpläne dienen.

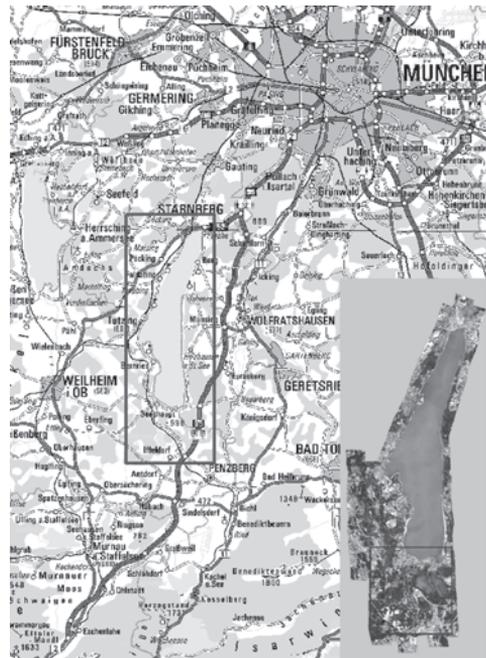


Abb. 1: Übersicht über Gesamtgebiet, Gesamtdatensatz und Testausschnitt Osterseen.

3 Datengrundlagen und Methoden

Im Vorfeld wurde eine unüberwachte Klassifikation (Isodata, K-means) durchgeführt,

um zu testen, ob sich auch mit dieser Methodik verwertbare Ergebnisse erzielen lassen.

Den Schwerpunkt der Auswertung stellte eine überwachte Klassifikation dar, wobei hier nur auf Maximum Likelihood eingegangen wird, das mit Abstand die besten Klassifikationsergebnisse erzielte.

Zunächst wurden vor Ort Trainingsgebiete mit einer Mindestgröße von 200 Pixel aufgenommen. Diese wurden anschließend spektralen Analysen unterzogen (Spektralprofile, Pixel Purity Index, Spektralkurven, Spectral Analyst). Diese Analysen ermöglichen einen Überblick über die Qualität von ausgewiesenen Trainingsklassen, ohne eine

Tab. 2: Getestete spektrale Indices, die sich für eine Klassifikation mit Maximum Likelihood eignen.

Name	Autor, Jahr	Berechnung lt. Autor	Berechnung mit CASI-Kanälen
Visible Ratios			
Carter	Carter, 1993	DN (695) / DN (420)	DN (693–703) / DN (489–499)
Lichtenthaler	Lichtenthaler et al., 1996	DN (440) / DN (690)	DN (489–499) / DN (681–692)
SRPI ¹	Peñuelas et al., 1995	DN (430) / DN (680)	DN (489–499) / DN (636–645)
SR (grün/blau)	George, 1997	DN (560) / DN (440)	DN(556–566) / DN (489–499)
Visible/NIR Ratios			
PSSRa	Lichtenthaler et al., 1996	DN (800) / DN (680)	DN (773–784) / DN (681–691)
PSSRb	Blackburn, 1998	DN (800) / DN (635)	DN (773–784) / DN (636–647)
PSSRc ²	Blackburn, 1998	DN (800) / DN (470)	DN (773–784) / DN (489–499)
Lichtenthaler	Lichtenthaler et al., 1996	DN (440) / DN (740)	DN (489–499) / DN (739–749)
Gitelson & Merzylak	Gitelson & Merzylak, 1996	DN (750) / DN (550)	DN (750–761) / DN (556–566)
PSNDa	Lichtenthaler et al., 1996	$\frac{DN(800) - DN(680)}{DN(800) + DN(680)}$	$\frac{DN(773-783) - DN(681-692)}{DN(773-783) + DN(681-692)}$
PSNDb	Blackburn, 1998	$\frac{DN(800) - DN(635)}{DN(800) + DN(635)}$	$\frac{DN(773-784) - DN(636-647)}{DN(773-784) + DN(636-647)}$
PSNDc ³	Blackburn, 1998	$\frac{DN(800) - DN(470)}{DN(800) + DN(470)}$	$\frac{DN(773-784) - DN(489-499)}{DN(773-784) + DN(489-499)}$
SAVI ⁴	Huete 1988	$\frac{DN(NIR) - DN(red) * (1+L)}{DN(NIR) + DN(red) + L}$ (L = [0;1])	NIR = 773–784, red = 681–692 NIR = 773–784, red = 681–692 (L = 0.5, 0.75, 1)
OSAVI ⁵	Rondeaux et al., 1996	$\frac{DN(NIR) - DN(red) * (1+L)}{DN(NIR) + DN(red) + L}$ (L = 0.16)	NIR = 773–784, red = 681–692
GNDVI ⁶	Gitelson et al., 1996	$\frac{DN(750) - DN(530-570)}{DN(750) + DN(530-570)}$	DN (750–761) – DN (556–566) DN (750–761) + DN (556–566)
SIPI ⁷	Zarco-Tejada, Miller, 1999	$\frac{DN(800) - DN(450)}{DN(800) + DN(650)}$	DN (773–783) – DN (489–499) DN (773–783) + DN (636–647)
Red Edge Reflectance Indices			
Gitelson & Merzylak	Lichtenthaler et al., 1996	DN (750) / DN (700)	DN (750–761) / DN (693–703)
Carter	Carter, 1993	DN (695) / DN (760)	DN (693–703) / DN (750–761)
Vogelmann	Vogelmann, 1993	DN (740) / DN (720)	DN (739–749) / DN (716–726)

¹ Simple Ratio Pigment Index

² Pigment-Specific Simple Ratio

³ Pigment-Specific Normalized Difference

⁴ Soil Adjusted Vegetation Index

⁵ Optimized Soil Adjusted Vegetation Index

⁶ Green Normalized Difference Veg. Index

⁷ Structure Intensive Pigment Index

zeitaufwendige Probeklassifikation durchführen zu müssen.

Die eigentliche Klassifikation wurde sowohl mit wenigen, durch Zusammenfassung verschiedener Landnutzungstypen entstandenen, Trainingsklassen als auch mit einer sehr großen Anzahl von bis zu 37 Klassen durchgeführt (s. Kap. 4.2, Tab. 3). Diese genaue Differenzierung ergab sich im Lauf der Probeklassifikationen, da sich so die Verwechslungsgefahr unterschiedlicher Trainingsklassen bestmöglich vermeiden ließ.

Verifiziert wurden die Ergebnisse in stichprobenartigen Kontrollgängen im Gelände sowie einer Confusion Matrix (Error Matrix) unter Berücksichtigung der Gesamtgenauigkeit bzw. κ -Koeffizient sowie Producer's und User's Accuracy. Diese Größen ergeben sich aus der Anzahl der korrekt klassifizierten Pixel in Relation zur Pixel-Gesamtzahl der Trainingsklasse (Producer's Accuracy) bzw. aus dem Verhältnis, in welchem die korrekt klassifizierten Pixel einer Klasse und die Gesamtzahl aller klassifizierten Pixel innerhalb einer Ergebnisklasse vorliegen (User's Accuracy). Ein hoher Wert für die Producer's Accuracy bedeutet demnach, dass die entsprechende Trainingsklasse weitgehend homogen ist, ein hoher Wert in der User's Accuracy dagegen, dass die erhaltenen Landbedeckungsklassen gut voneinander zu trennen sind.

Zur Verbesserung der Ergebnisse fanden im nächsten Schritt arithmetische Operationen zwischen einzelnen Kanälen statt. Die

getesteten spektralen Indices lassen sich in Visible Ratios, Visible/NIR Ratios und Red Edge Reflectance Indices einteilen (s. Tab. 2).

Da eine Klassifikation mit allen in der Literatur (JACKSON et al. 1983, CLEVERS 1990, GAMON et al. 1992 u. a.) verwendeten Indices zu aufwendig geworden wäre, wurden nur diejenigen verwendet, deren Grauwerte innerhalb der Trainingsklassen keine allzu große Streuung aufwiesen. Als Maß zur Auswahl dienten Mittelwert und Median der Standardabweichungen der Grauwerte über alle Trainingsklassen im NIR-Kanal mit der Bandbreite 773 bis 784 nm, weil dieser im Datensatz ein Reflexionsmaximum für Vegetation – und daher für alle relevanten Klassen – darstellte. Abb. 2 zeigt Mittelwert und Standardabweichung der Grauwerte jeder Klasse für den betreffenden NIR-Kanal sowie beispielhaft für den Red Edge Index GITELSON & MERZYLAKE, einer der am besten geeigneten Indices für eine Maximum Likelihood-Klassifikation (s. Kap. 4.3).

Aus der Grauwertverteilung über die einzelnen Klassen für diesen NIR-Kanal ergab sich, dass die Standardabweichung vom mittleren Grauwert einer Klasse über alle Klassen gerechnet ein arithmetisches Mittel von 20,4% aufwies. In Anlehnung an diesen Wert wurde das zulässige Maximum für die mittlere Standardabweichung eines Vegetationsindex' auf einen etwas höheren Wert (25%) gesetzt. Um Extremwerte einzelner

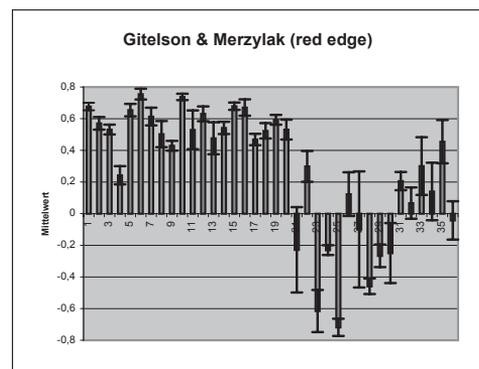
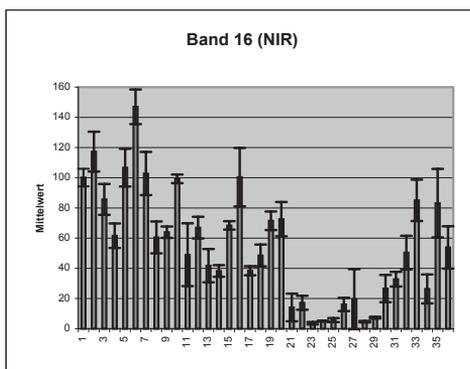


Abb. 2: Grauwertverteilung (Mittelwert und Standardabweichung) aller Trainingsklassen für den NIR-Kanal 16 (773 bis 784 nm) und den Vegetationsindex GITELSON & MERZYLAKE (NIR/Rot).

Klassen nicht zu sehr zu gewichten, wurde zudem der Median der Standardabweichungen berücksichtigt. Dieser betrug beim o.g. NIR-Kanal 14,9%.

Indices, deren Standardabweichungen im Mittel mehr als 25% vom mittleren Grauwert der jeweiligen Klasse betrugten und deren Standardabweichungen einen Median von mehr als 15% ergaben, wurden nicht für die Klassifikation verwendet.

Die verbleibenden spektralen Indices wurden – nach Streckung auf 256 Grauwerte (8 bit) – zunächst einzeln zu den bestehenden 20 CASI-Kanälen hinzugefügt, klassifiziert und verifiziert. Danach erfolgten weitere Klassifikationen mit verschiedenen Kombinationen von spektralen Indices (z. B. nach Art ihrer Berechnung, den verwendeten Kanälen oder durch Kombinationen derjenigen Indices, die die höchsten Werte für Producer's und User's Accuracy ergaben). Die Tests der Vegetationsindices erfolgten zur Einsparung von Rechenzeit mit einem Subset, das die Osterseen und den südlichen Teil des Starnberger Sees beinhaltete (s. Abb. 1).

Das endgültige Klassifikationsergebnis resultierte aus einer Mischung aus vier Datensätzen, kombiniert mit unterschiedlichen spektralen Indices, wobei immer diejenige Klasse zur Weiterverarbeitung ausgewählt wurde, die den höchsten ungewichteten Mittelwert aus Producer's und User's Accuracy aufwies.

Die Einzelpixel ausgewählter klassifizierter Datensätze wurden anschließend durch eine Kombination aus Minimum- und Maximumfilter und einer 3×3 -Filtermatrix eliminiert. Anschließend wurden alle Ergeb-

nisklassen in Vektordaten umgewandelt. Die grafische Darstellung erfolgte anhand von Themenkarten (Maßstab 1:15 000 bzw. 1:5 000).

4 Ergebnisse

4.1 Unüberwachte Klassifikation

Das optimale Ergebnis bei der unüberwachten Klassifikation wurde mit 5 Klassen erreicht. Wurden mehr als 5 Klassen definiert, ergab sich lediglich eine (offenbar willkürliche) feinere Differenzierung im Bereich der Wälder, wobei einem Baum z. T. Pixel unterschiedlicher Klassen zugeordnet wurden.

Am deutlichsten erfolgte die Abgrenzung von Wasser- und Ackerflächen. Weitere Klassen waren Grünland, Feuchtsflächen und eine Mischklasse, bestehend aus Straßen, Mooren, Röhricht und Bäumen, wodurch die beschränkte Einsetzbarkeit dieser Art von Klassifikation bezüglich der Unterscheidung verschiedener Landnutzungstypen deutlich wird.

4.2 Maximum Likelihood-Klassifikation

Bei der überwachten Klassifikation nach dem Maximum Likelihood-Verfahren war ein deutlicher Zusammenhang zwischen dem Ergebnis der Klassifikation und den spektralen Analysen zu erkennen: Die besten Klassifikationsergebnisse lieferten Gewässer und Ackerflächen, anhand deren Spektralkurven ersichtlich wurde, dass die mittleren Grauwerte dieser Trainingsklassen die geringsten Standardabweichungen besa-

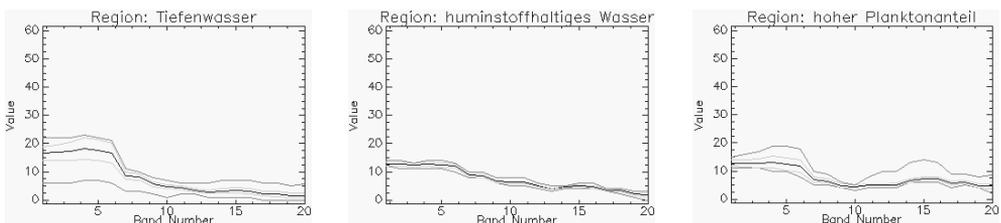


Abb. 3: Spektralkurven unterschiedlicher Gewässertypen (dargestellt sind mittlerer Grauwert (= mittlere Linie), Standardabweichung und maximaler bzw. minimaler Grauwert (= äußere Linien) im jeweiligen Kanal).

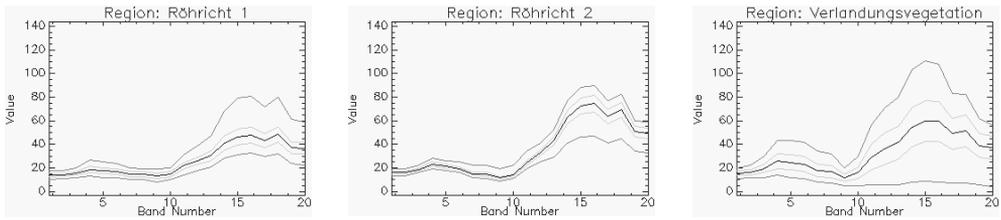


Abb. 4: Spektralkurven für verschieden Arten von Feuchtgebietvegetation.

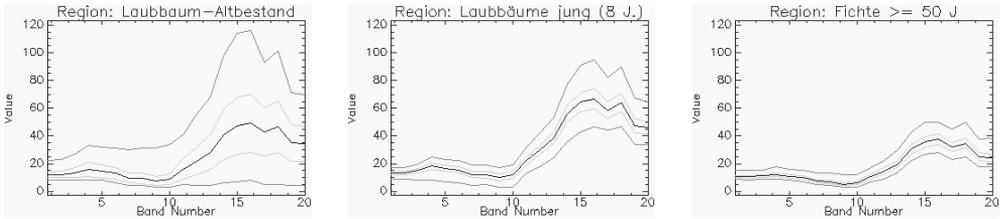


Abb. 5: Spektralkurven für Laubbäume und Fichten.

Tab. 3: Alle Landnutzungsklassen; --- = in der Landnutzungskarte zu einer Klasse zusammengefasst.

Landwirtschaftsflächen	Bäume	Vegetation der Feuchtgebiete und Gewässer	Wasserflächen	Siedlungs- und Verkehrsflächen
Mais	Fichten (≤ 15 J.)	Feuchtwiese	Tiefenwasser	Bahnlinie
Zwischensaat	Fichten (35–40 J.)	gemähte Feuchtwiese	mittlere Tiefe	Asphalt
Stoppelfeld	Fichten (≥ 50 J.)	Hochstauden	Flachwasser	Kies
unbedeckter Boden	Kiefern	Röhricht, Großseggenried	Sediment	Dach (Sonnenseite)
trockene Mähwiese	Hasel	Schilf	planktonreiches Wasser	Dach (Schattenseite)
frische Mähwiese	Laubbäume (ohne Hasel)	Hochmoor	Kleingewässer	Boote, Anleger
Weide	Laubbaum-Jungbestand (≤ 8 J.)	Verlandungsvegetation	huminstoffhaltiges Wasser	
Grünland gemäht		Schwimblattvegetation		
		submerse Vegetation		

ßen. Verschiedene Gewässertypen ließen sich zudem gut durch ihren unterschiedlichen Anteil an Plankton und Huminstoffen unterscheiden (s. u.).

Eine breite Streuung der Grauwerte zeigte sich dagegen bei Siedlungs- und Verkehrsflächen, die auch im klassifizierten Datensatz nicht immer deutlich zu erkennen waren. Bezüglich Vegetation zeichneten sich sowohl in den Spektralkurven als auch in der Klassifikation Vegetationseinheiten ab, die im Originaldatensatz optisch nicht ohne weiteres zu unterscheiden waren: So wurden beispielsweise zwei Typen von Röhricht klassifiziert (s. Abb. unten), die sich in Dichte und Schilfanteil unterschieden, des weiteren unterschiedliche Typen aquatischer Vegetation.

Am wenigsten befriedigend fiel das Klassifikationsergebnis für Bäume aus. Einzelne Laubbaumarten ließen sich gar nicht, Altersstufen nur partiell unterscheiden. Lediglich Fichten hoben sich gut von allen anderen Baumarten ab. Auch hier zeigt sich deutlich der Zusammenhang zwischen Klassifikationsergebnis und Standardabweichungen der Spektralkurven (Abb. 5).

Die Schwierigkeit der korrekten Klassifikation von Wald und Siedlung wurde bei Betrachtung des Klassifikationsergebnisses sofort durch das uneinheitliche Erscheinungsbild dieser beiden Landnutzungsformen, den so genannten „Pfeffer- und Salz-Effekt“, deutlich.

Mit Ausnahme der Laubbaumgattungen ist es bei dieser Art hoch auflösender Daten dennoch empfehlenswert, Trainingsklassen möglichst differenziert auszuweisen, um Verwechslungen verschiedener Landnutzungsformen zu minimieren. Insgesamt ergaben sich 37 Landnutzungsklassen (s. Tab. 3), die in der Landnutzungskarte zu 26 Klassen zusammengefasst wurden.

4.3 Klassifikation mit spektralen Indices

Unter Berücksichtigung der Standardabweichungen vom mittleren Grauwert einzelner Klassen schieden u. a. die meisten Normalized Difference Indices insofern aus, als

ihre Grauwerte in den einzelnen Klassen eine zu hohe Standardabweichung vom mittleren Grauwert aufwiesen. Dies steht für eine zu breite Streuung der Pixelwerte, was zur Folge hat, dass sich verschiedene Trainingsklassen innerhalb des entsprechenden Vegetationsindex' nicht deutlich genug voneinander unterscheiden lassen. Bei den betreffenden Indices handelte es sich um:

- PRI (Photochemical Reflectance Index)
- NPCI (Normalized Pigment Chlorophyll Ratio Index)
- DVI (Difference Vegetation Index)
- DDVI (Difference Difference Vegetation Index)
- ARVI (Atmospherically Resistant Vegetation Index)
- GEMI (Global Environmental Monitoring Index)
- Vogelmann (berechnet als Normalized Difference Index)

Des Weiteren ließ sich mit einigen Indices aufgrund ihrer hohen Abweichung von der Normalverteilung aller Grauwerte (s. Kap. 5.3) gar keine Maximum Likelihood-Klassifikation in ENVI durchführen. Betreffende Indices waren:

- PSND_a (Pigment-Specific Normalized Difference)
- TVI (Transformed Vegetation Index)
- IPVI (Infrared Percentage Vegetation Index)
- SAVI (Soil Adjusted Vegetation Index)
- MSAVI2 (Second Modified Soil Adjusted Vegetation Index)

Beim Vergleich der Klassifikationsergebnisse schnitten Simple Ratios, also durch einfache Verhältnisbildung berechnete Indices, in der Regel am besten ab. Allerdings ließ sich kein Index finden, der für sämtliche Klassen eine Verbesserung des Ergebnisses bewirkt hätte.

Untenstehende Tabelle zeigt Producer's und User's Accuracy einiger ausgewählter Landbedeckungsklassen mit verschiedenen Vegetationsindices. Auffallend sind einerseits die großen Unterschiede einzelner Klassen über die Indices, andererseits die fast durchgängig höheren Werte, die bestimmte (v. a. Simple Ratio) Indices erreichten.

Tab. 4: Producer's Accuracy für ausgewählte spektrale Indices und Klassen

producer's accuracy (%)	CASI-Originaldaten	Originaldaten in Kombination mit:								CASI-Daten und 5 Indices*	CASI-Daten und alle Indices
		SRPI (b/rot)	PSSRa (NIR/rot)	PSSRc (NIR/b)	Lichtenthaler (b/NIR)	PSND b (NIR: rot)	SIPI (NIR:bl.:rot)	Gitelson & Merzylak (red e.)			
<i>Trainingsklasse</i>											
Mais	99,12	99,07	99,23	99,49	99,4	99,55	99,56	99,1	99,67	97,9	
Zwischensaat	99,78	99,31	99,46	99,74	99,65	99,13	99,37	99,55	99,96	93,74	
trockene Mähwiese	85,9	88,52	90,16	89,51	84,92	83,28	84,59	90,49	87,15	78,36	
frische Mähwiese	79,49	85,62	89,19	79,78	80,51	72,03	64,34	87,75	99,84	15,67	
Feuchtgrünland	62,73	62,82	60,96	59,44	63,58	61,55	61,38	62,73	83,68	54,81	
gemähtes Feuchtgrünland	97,75	98,31	98,03	94,1	98,6	96,63	97,47	97,75	98,6	96,91	
Laubbäume	48,29	45,68	50,24	47,31	38,01	42,74	39,8	47,47	38,16	33,77	
Laubbaum-Jungbestand	59,47	61,24	56,51	66,27	75,74	72,19	73,96	62,13	89,33	38,17	
Kiefern	72,48	72,48	73,83	73,83	67,79	73,15	73,83	75,84	81,67	68,46	
Fichten (alt)	94,51	94,51	94,7	95,27	96,59	96,59	96,02	94,32	96,62	94,89	
Fichten (jung)	98,78	98,78	98,78	98,78	99,39	99,39	99,39	98,78	96,95	93,29	
Röhricht 1	89,42	92,7	92,11	89,61	87,27	85,12	85,12	92,46	96,8	84,19	
Röhricht 2	83,33	88,62	78,46	88,62	86,59	76,02	80,89	88,21	98,99	73,98	
Schwimblattvegetation	80,39	78,92	84,31	84,31	81,86	82,84	80,88	85,29	83,82	37,75	
submerse Vegetation	100	89,29	89,29	89,29	85,71	89,29	89,29	89,29	100	0	
Tiefenwasser	96,82	97,04	96,88	97,35	99,23	96,88	99,76	99,56	99,33	10,38	
Flachwasser	100	100	100	100	100	100	100	100	99,35	93	
planktonreiches Wasser	74,7	75,9	63,86	96,39	100	85,54	99,4	92,17	99,7	74,7	
Bahnlinie	83,13	80,15	79,39	80,92	80,15	80,92	83,97	80,15	98,47	87,79	
Asphalt	92,4	93,3	92,3	93,1	92,7	92,8	92,8	92,4	95,3	93,8	
Dach (Sonnenseite)	91,88	90,86	91,88	90,86	90,86	90,86	90,86	91,88	93,67	21,83	
Mittelwert	85	88	85	88	89	88	88	89	94	71	

* SRPI, PSSRc, Lichtenthaler, SIPI, G&M

Tab. 5: User's Accuracy für ausgewählte Indices und Klassen.

user's accuracy (%)	CASI-Originaldaten	Originaldaten in Kombination mit:								CASI-Daten und 5 Indices*	CASI-Daten und alle Indices
		SRPI (b/rot)	PSSRa (NIR/rot)	PSSRc (NIR/b)	Lichtenthaler (b/NIR)	PSND b (NIR: rot)	SIPI (NIR:bl.:rot)	Gitelson & Merzylak (red e.)			
<i>Ergebnisklasse</i>											
Mais	100	100	100	100	100	100	100	100	99,99	99,96	
Zwischensaat	100	100	100	100	100	100	100	100	99,95	100	
trockene Mähwiese	11,64	13,31	18,47	11,37	11,96	13,75	11,8	14,56	45,68	14,18	
frische Mähwiese	100	100	100	100	100	100	100	100	100	100	
Feuchtgrünland	81,76	84,47	86,69	79,57	81,96	80,4	80,89	86,51	87,65	75,93	
gemähtes Feuchtgrünland	91,1	87,28	82,9	83,33	89,31	86,43	88,97	85,5	81,74	69,28	
Laubbäume	49,66	33,41	32,15	54,31	55,74	51,37	53,98	45,54	81,83	56,87	
Laubbaum-Jungbestand	48,55	59,65	59,87	53,33	45,23	42,88	41,12	57,85	75,56	39,94	
Kiefern	33,86	35,41	40,74	35,03	35,94	36,58	35,83	39,37	56,45	39,38	
Fichten (alt)	88,95	86,33	86,96	85,54	87,18	87,48	87,26	88,14	87,8	83,22	
Fichten (jung)	95,29	93,64	94,74	91,01	93,14	87,63	89,07	95,86	87,12	89,47	
Röhricht 1	86,28	86,42	85,78	85,79	85,5	84,99	85,09	86,27	97,52	84,72	
Röhricht 2	90,71	87,55	88,13	90,83	89,87	90,34	88,05	89,3	87,84	66,91	
Schwimblattvegetation	73,87	67,93	55,84	63,24	63,26	59,72	62,03	71,9	61,29	43,75	
submerse Vegetation	100	100	100	100	100	100	100	100	100	0	
Tiefenwasser	99,99	99,99	99,99	100	99,98	99,97	99,98	99,98	99,96	96,56	
Flachwasser	97,51	99,87	99,48	99,4	98,93	82,23	96,86	99,7	100	98,58	
planktonreiches Wasser	10,47	12,45	8,74	13,32	36,64	16,1	87,77	54,84	95,93	98,41	
Bahnlinie	97,2	98,13	97,2	96,36	98,13	98,15	100	95,45	88,97	97,46	
Asphalt	88,68	89,11	90,4	91,63	87,54	91,52	91,43	89,97	97,65	94,37	
Dach (Sonnenseite)	78,35	82,49	74,49	73,97	67,8	74,9	51,59	79,39	92,27	68,25	
Mittelwert	77	81	76	81	82	79	82	82	87	77	

* SRPI, PSSRc, Lichtenthaler, SIPI, G&M

Für den gesamten Datensatz erzielten die Simple Ratio Indices LICHTENTHALER (489 bis 499 nm/ 739 bis 749 nm) und der Red Edge Index GITELSON & MERZYLAK (773 bis 784 nm/ 681 bis 692 nm) die besten Ergebnisse.

Eine Kombination von spektralen Indices bewirkte zumeist eine Verschlechterung des Datensatzes. Eine Ausnahme stellte eine Kombination aus den Indices SRPI, PSSRc, LICHTENTHALER, SIPI und GITELSON & MERZYLAK dar.

Nach Klassifikation mit den entsprechenden Indices erfolgte eine Bewertung der Ergebnisse durch die Error Matrix. Eine Klasse wurde als gut klassifiziert ausgewiesen, wenn die Producer's bzw. User's Accuracy einen Wert von mindestens 90 % besaß, ein unbefriedigendes Ergebnis liegt dann vor, wenn der Wert einer Accuracy unter 70 % liegt. Diese Richtwerte ergaben sich sowohl aus einem Vergleich von Ergebnisklassen mit stichprobenartigen Kontrollen im Gelände als auch aus Beispielen aus der Literatur (FOODY 2001).

Tab. 6: Bewertung von Producer's (oben) und User's Accuracy (unten) des Gesamtdatensatzes („gut“ $\geq 90\%$, $70\% \leq$ „ausreichend“ $< 90\%$, „unbefriedigend“ $< 70\%$).

Producer's Accuracy

Gute Ergebnisse	Ausreichende Ergebnisse	Unbefriedigende Ergebnisse
18 (20*) Klassen: Mais, Zwischensaat, unbedeckter Boden, gemähte Feuchtwiese, Hasel, Fichten (≤ 15 J.), Hochmoor, Röhricht, submerse Vegetation, Schatten, Tiefenwasser im Schatten, mittlere Tiefe, Flachwasser, Kleingewässer, Sediment, huminstoffhaltiges Wasser, planktonreiches Wasser.	14 (13*) Klassen: Stoppelfeld*, trockene Mähwiese*, frische Mähwiese, Fichten (> 35 J.), Hochstauden, Schwimmblattvegetation, Verlandungsvegetation, Tiefenwasser, Bahnlinie, Asphalt, Kies, Dachflächen, Boote.	5 (4*) Klassen: Weide/gemähte Wiese, Feuchtwiese, Laubbäume, Laubbaum-Jungbestand, Kiefern*.

User's Accuracy

Gute Ergebnisse	Ausreichende Ergebnisse	Unbefriedigende Ergebnisse
15 (16*) Klassen: Mais, Zwischensaat, Stoppelfeld, unbedeckter Boden, frische Mähwiese, Hasel, Hochmoor, Röhricht, submerse Vegetation, Schatten, Tiefenwasser, mittlere Tiefe, Flachwasser, huminstoffhaltiges Wasser.	11 (13*) Klassen: Weide/gemähte Wiese, Feuchtwiese, gemähte Feuchtwiese, Fichten (≤ 15 J.), Fichten (> 35 J.), Verlandungsvegetation, Tiefenwasser im Schatten, Asphalt, Dachflächen, Boote.	11 (8*) Klassen: Trockene Mähwiese, Laubbäume, Laubbaum-Jungbestand, Kiefern, Hochstauden, Schwimmblattvegetation*, Kleingewässer**, planktonreiches Wasser, Sediment*, Bahnlinie, Kies.

() *Verbesserung um eine (zwei) Stufe(n) nach Klassifikation mit einem spektralen Index*

Tab. 6 gibt die Bewertung des Klassifikationsergebnisses anhand der Producer's und User's Accuracy für die einzelnen Klassen wieder.

Auch wenn sich generell die Frage stellt, ob die Verbesserungen der Klassifikationsergebnisse durch Hinzunahme spektraler Indices den hohen Aufwand solcher Untersuchungen rechtfertigen, ist festzuhalten, dass die Indices LICHTENTHALER (blau/NIR) und GITELSON & MERZYLAK (NIR/rot) für die Auswertung hochauflösender Hyperspektraldaten eine interessante Möglichkeit zur Verbesserung der Klassifikationsergebnisse darstellen können.

5 Diskussion

5.1 Unüberwachte Klassifikation

Bereits durch die unüberwachte Klassifikation wird deutlich, dass im vorliegenden Datensatz mit einer räumlichen Auflösung von 3 m nur Gewässer und Ackerflächen aufgrund ihrer relativen spektralen Homogenität eindeutig klassifiziert werden können. Dagegen tritt v.a. bei Bäumen das Problem der Mischpixel deutlich zutage. Dieses be-

ruht auf Unterschieden in der Licht- und Schattenverteilung innerhalb der Krone sowie in Behaarung und Stellung der Blattoberfläche. Daher konnte innerhalb der unüberwachten Klassifikation keine eigene Klasse für Wald entstehen.

Auch Siedlungs- und Straßenflächen weisen aufgrund von vieler Mischpixel, bedingt durch den Übergang unterschiedlicher Materialien und Oberflächen (Asphalt, Beton, Materialablagerungen, Übergänge zu Grünflächen), eine hohe spektrale Streuung auf und konnten keiner eigenen Klasse zugeordnet werden.

5.2 Maximum-Likelihood-Klassifikation

Da die überwachte Klassifikation die Möglichkeit bietet, gezielt Trainingsgebiete für bestimmte Landnutzungsformen zu definieren, ließen sich unkorrekte Klassifikationsergebnisse durch differenziertere Ausweisung von Trainingsklassen wesentlich besser beheben.

Die unterschiedlichen Gewässertypen ergaben sich aufgrund von Tiefe und stofflicher Zusammensetzung der jeweiligen Ge-

wässer: Klares Tiefenwasser wies ein deutliches Reflexionsmaximum im Blaukanal auf, während Flachwasser, bedingt durch das darunter befindliche Sediment aus See-tonen bzw. Seekreide, eine gelbliche Färbung annahm. Bei planktonreichem Wasser, v. a. Kleingewässern, verschob sich das Reflexionsmaximum in Richtung Grün, obwohl sich dies allein anhand rein visueller Auswertung der Daten nicht feststellen ließ. Genaue Angaben über die Phytoplankton-Konzentration der entsprechenden Seen am Tag der Befliegung lagen leider nicht vor. Untersuchungen mit CASI bei Seen in Wales hatten allerdings ergeben, dass Plankton bereits bei sehr geringen Mengen ($0,5 \mu\text{g/l}$) die spektrale Signatur beeinflussen kann (GEORGE & MALTHUS 2001).

Huminstoffe senkten die Reflexion im gesamten Spektralbereich.

Spektrale Analysen zeigten für alle Arten von Vegetation einen relativ einheitlichen Red Edge (Wendepunkt der Steigungskurve zwischen Rot und NIR) bei ca. 730 nm, mit Ausnahme von submerser Vegetation, die, bedingt durch die Absorption von Wasser im NIR, nur einen Reflexionsmaximum im Grünen aufwies. Alle anderen Vegetationsformen ließen sich daher anstelle des Red Edge lediglich durch ihr Reflexionsmaximum im NIR unterscheiden, das eine Reichweite von 20 DN für Schwimmblattvegetation bis 140 DN (von 256 möglichen Grauwerten) für Mähwiese aufwies.

Für Äcker spielte das Alter des Bestandes insofern eine Rolle, als frisch ausgesäte Zwischensaat eine höhere Reflexion im NIR und Grün zeigte als seneszente Maispflanzen am Ende der Vegetationsperiode. Verschiedene Grünlandarten ließen sich dagegen eher anhand der Feuchte (rötliches Pfeifengras als dominante Feuchtwiesenpflanze) und der Regelmäßigkeit von Mahd oder Beweidung unterscheiden.

Das Zustandekommen zweier verschiedener Röhricht-Typen ist mit hoher Wahrscheinlichkeit darauf zurückzuführen, dass dichte, (fast) reine Schilfbestände eine bedeutend höhere Reflexion aufweisen als ein Mosaik aus Seggenried, Schilf und Feuchtwiesenvegetation. Unterschiedliche Arten

aquatischer Vegetation ließen sich insofern differenzieren als das Reflexionsmaximum im NIR von der Vegetation der Verlandungszone über Schwimmblattvegetation bis zur submersen Vegetation kontinuierlich abnahm (letztere wies nur noch einen Peak im Grünen auf, da das umgebende Wasser die Reflexion im NIR vollständig absorbierte).

Die Wirkung von Zellstrukturen ist nur bei der Unterscheidung von Nadel- und Laubbäumen entscheidend, da Nadeln einen größeren Anteil an Interzellularen besitzen, die die Absorption von Strahlung erhöhen (BACH 1995). Laubbaumgattungen konnten nicht unterschieden werden, da die Wirkung von Licht- und Schattenverteilung, Kronendichte u. a. oft mehr von einzelnen Individuen bzw. deren Standort abhängt.

Alle hier angeführten Betrachtungen bezüglich verschiedener Vegetationsformen gelten natürlich nur für den Monat September. Vermutlich wäre für die Erfassung mancher Vegetationseinheiten (z. B. Wasserpflanzenrasen) eine Befliegung im Hochsommer günstiger gewesen.

Zuletzt bleibt noch zu beantworten, warum die Auswertungsergebnisse für sämtliche Klassen im Subset besser ausfielen als im gesamten digitalen Bild. Ein Grund ist, dass in der gesamten Szene die Uferbereiche des Starnberger Sees enthalten sind. Diese zeichnen sich durch kleinräumige Übergänge zwischen Wasser und Land aus, die mit vorliegender Auflösung nicht immer genau abzugrenzen sind. Außerdem wirken sich Luftlichtüberlagerungen oder atmosphärische Streuungen auf größerer Fläche stärker aus. Deutlich wird dies beispielsweise anhand des Starnberger Sees, dessen Wasseroberfläche wesentlich mehr fehlklassifizierte Pixel aufwies als die der Osterseen. Des Weiteren äußern sich durch Dreh- und Kippbewegungen des Flugzeugs hervorgerufene Veränderungen des Einfallswinkels der Reflexion auf eine Länge von 30 km drastischer als in einem Ausschnitt der gesamten Szene von nur wenigen Kilometern Länge.

5.3 Klassifikation mit spektralen Indices

Je aufwendiger ein (Vegetations-)Index berechnet ist, desto unregelmäßiger ist die Grauwertverteilung aller Pixel im zu klassifizierenden Datensatz. Dies ist auch der Grund, warum die Trainingsklassen innerhalb der Simple Ratios niedrigere Standardabweichungen vom mittleren Grauwert besitzen als innerhalb der Normalized Difference und komplexerer Indices.

Folgende Abbildung zeigt die Grauwert-histogramme eines „einfachen“ Index' (PSSR_b) im Vergleich zu komplizierter berechneten (hier stellvertretend IPVI und MSAVI2) Indices.

Hierbei wird deutlich, dass die Verteilung der Grauwerte nur bei der Simple Ratio PSSR_b wenigstens annähernd einer Normalverteilung entspricht. Da diese Normalverteilung aber für eine Maximum Likelihood-Klassifikation absolute Voraussetzung ist, wird deutlich, warum sich mit den Indices MSAVI2 und IPVI, wie auch mit (D)DVI und TVI, keine Klassifikation durchführen ließ.

Das gute Ergebnis des Red Edge Index GITELSON & MERZYLAK verwundert nicht, da dieser genau die Wellenlängen miteinander verbindet, die im Datensatz das Reflexionsmaximum für Vegetation (773 bis 784 nm) und das Reflexionsmaximum für unbewachsene Oberflächen (635 bis 680 nm) bzw. Reflexionsminimum für Vegetation darstellen. Zu beachten ist hier allerdings, dass der NIR-Bereich von 725 nm bis 829 nm im vorliegenden CASI-Datensatz für Auswertungen nicht zur Verfügung stand.

Die relativ guten Resultate, die durch eine NIR/Blau-Kombination erzielt wurden (LICHTENTHALER, PSSR_c), basieren vermutlich auf dem unterschiedlichen Reflexionsverhalten von chlorophyllarmem und -reichem Wasser innerhalb des Blau- bzw. NIR-Bereichs, da sich bei einer Division der entsprechenden Kanäle die erzielten Grauwerte mit zunehmendem Bewuchs der Wasserflächen vermindern (Lichtenthaler) bzw. steigern (PSSR_c). Angesichts des hohen Anteils von Gewässern und Feuchtflächen im Untersuchungsgebiet bieten sich diese beiden Indices geradezu an.

Wie bereits in anderen Untersuchungen beobachtet (RONDEAUX et al. 1996), können sich Vegetationsindices in ihrer Wirkung aufheben. Auch in dieser Arbeit zeigte sich, dass eine Kombination von zu vielen bzw. allen Vegetationsindices das Ergebnis drastisch verschlechterte. Der Grund liegt in der Kombination von zu vielen Bändern mit nicht normalverteilten Grauwerten. Allerdings besteht die Tendenz, dass Indices, deren Grauwerte annähernd normalverteilt sind, auch in Kombination gut verwendet werden können, so z. B. LICHTENTHALER, PSSR_c, GITELSON & MERZYLAK, SRPI und SIPI. Diese Indices werden ausschließlich aus Wellenlängen im Blau-, Rot- und NIR-Bereich berechnet.

Abschließend soll darauf hingewiesen werden, dass sich oben genannte Ergebnisse speziell auf CASI-Daten vom September beziehen. Es ist vorstellbar, dass sich bei Untersuchungen mit anderen Sensoren oder zu einer anderen Jahreszeit die zur Berechnung von Vegetationsindices optimalen Wellenlängen etwas verschieben können. Allgemeine Erkenntnisse, beispielsweise die bevor-

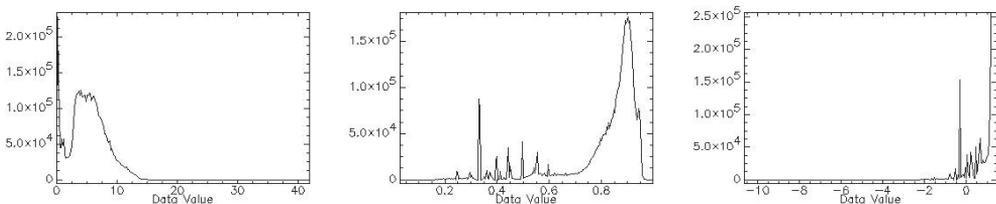


Abb. 6: Grauwert-histogramme der Indices PSSR_b (links), IPVI (Mitte), MSAVI2 (rechts).

zugte Verwendung von Simple Ratio Indices oder die gute Eignung von Wellenlängen in Rot und NIR, die Beginn bzw. Ende des Reflexionsanstiegs für Vegetation darstellen, lassen sich nach Auffassung der Autorin jedoch auch auf entsprechend ähnliche Auswertungsmethoden anderer Datensätze übertragen.

6 Zusammenfassung und Schlussbemerkungen

Die Analyse der im September 1999 aufgenommenen CASI-Daten ergab, dass die günstigste Vorgehensweise für eine Maximum Likelihood-Klassifikation eine Ausweisung von möglichst vielen Trainingsklassen (in diesem Fall 37) ist, um Verwechslungen von Klassen weitgehend vorzubeugen. Die besten Klassifikationsergebnisse entstanden für große, homogene Landbedeckungsformen wie Wasser- oder Ackerflächen.

Gemessen an der Auflösung von $3\text{ m} \times 3\text{ m}$ pro Pixel ließen sich Gewässer und Feuchtflächen relativ genau differenzieren. Verschiedene Gewässertypen waren anhand von Tiefe und Trübung durch Plankton oder Huminstoffe gut zu unterscheiden. Verschiedene Feuchtgebiete ließen sich durch unterschiedliche Vegetation einteilen (Hochmoor, Niedermoor, Verlandungszonen, Röhrichte unterschiedlicher Zusammensetzung). Am wenigsten gut geeignet für eine Klassifikation nach Maximum Likelihood waren Bäume und versiegelte Oberflächen.

Von den getesteten spektralen Indices erwiesen sich nur wenige als eine echte Verbesserung für das Klassifikationsergebnis. Berechnet wurden Indices mit Wellenlängen im sichtbaren Licht, „klassische“ Vegetationsindices (NIR/rot) und Red Edge Indices. Außerdem wurden sowohl Simple Ratios (durch einfache Verhältnisbildung entstandene Indices) berücksichtigt als auch Normalized Difference und komplizierter errechnete Indices (IPVI, TVI, GEMI, MSAVI2).

Eine wesentliche Erkenntnis war, dass kein Index ermittelt werden konnte, der für

alle Landnutzungsklassen eine optimale Verbesserung darstellte. Außerdem bewirkten die Simple Ratios zum großen Teil die besten Resultate, gemessen an Producer's und User's Accuracy der einzelnen Klassen.

Die Wellenlängen der am besten geeigneten Indices lagen in den Bereichen NIR-Rot (Reflexionsmaximum bzw. -minimum für Vegetation und Boden) und NIR-Blau. Eine Kombination von Vegetationsindices wirkte sich zumeist negativ auf das Klassifikationsergebnis aus. Eine Ausnahme stellten die Indices SIPI, PSSR_c, LICHTENTHALER, SRPI und GITELSON & MERZYLAK dar, die sich sowohl einzeln als auch in Kombination gut verwenden ließen.

Auch wenn sich in Fall vorliegender Untersuchungen etliche Landbedeckungsformen, z. B. verschiedene Feuchtgebiete, relativ differenziert erfassen ließen (reine gegenüber gemischten Schilfbeständen, Feuchtwiesen in Unterscheidung zu mäßig feuchtem Grünland), zeichnet sich doch ab, dass Fernerkundung, zumindest in Zusammenhang mit überwachter Klassifikation, auch in Zukunft nicht den Gang ins Gelände ersetzen wird. Beispielsweise lassen sich im Gebiet nur Vegetationseinheiten, erkennbar durch massenhaft auftretende Individuen derselben Art, unterscheiden, jedoch sind keine feineren Unterteilungen wie einzelne Gesellschaften auszumachen. Außerdem ist nicht jede Art von Vegetation zu erfassen: Waldbodenpflanzen geben beispielsweise kein Signal zurück. Flächen mit hohem Mischpixelanteil (wie Ruderalstellen) sind ebenfalls sehr problematisch.

Trotz aller Schwierigkeiten sind Fernerkundungsdaten in der Regel gut geeignet für Voruntersuchungen, vor allem bei weit auseinander liegenden und/oder schwierig zugänglichen Biotopen. So kann eine Befliegung etwa die Entscheidung erleichtern, welche Gebiete überhaupt für eine Probenahme lohnenswert sind.

Ein weiterer Vorteil besteht darin, dass eine automatisierte Klassifikation weniger subjektiv ist als eine rein visuelle Interpretation. Des Weiteren besteht die Möglichkeit, Rasterdaten ohne Schwierigkeit in Vektordaten umzuwandeln, welche zur weiteren

Auswertung und grafischen Verarbeitung wesentlich besser geeignet sind.

Danksagung

Danken möchte ich an dieser Stelle Prof. ARNULF MELZER sowie den Mitarbeitern der Limnologischen Station Iffeldorf für die Einrichtung eines hervorragend ausgestatteten Arbeitsplatzes. Fachliche Unterstützung erhielt ich außerdem durch die Mitarbeiter im AQUATIC-Projekt Dr. THOMAS SCHNEIDER, Dipl.-Geogr. THORSTEN ANDRESEN, Dipl.-Biol. CLAUDIUS MOTT und Dipl. Ing. (FH) STEFAN ZIMMERMANN.

Literatur

- BACH, H., 1995: Die Bestimmung hydrologischer und landwirtschaftlicher Oberflächenparameter aus hyperspektralen Fernerkundungsdaten. – Dissertation am Institut für Geographie der Universität München – 1. Aufl., 175 S., Geobuch-Verlag, München.
- BLACKBURN, G.A., 1999: Relationships between Spectral Reflectance and Pigment Concentrations in Stacks of Deciduous Broadleaves – Remote Sensing of Environment, **70** (2): 224–237.
- BUITEN, H. & CLEVERS, J. (Hrsg.), 1990: Land observation by remote sensing, theory and applications – 1sted., S., Gordon and Breach Science Publishers, Wageningen.
- FOODY, G.M., 2001: Status of land cover classification accuracy assessment – Remote Sensing of Environment, **80** (1): 185–201.
- GEORGE, D.G. & MALTHUS, T.J., 2001: Using a compact airborne spectrographic imager to monitor phytoplankton biomass in a series of lakes in north Wales – The Science of the Total Environment, **268** (1): 215–226.
- GROSSER, S., POHL, W. & MELZER, A., 1996: Untersuchung des Schilfrückgangs an bayerischen Seen – 1. Aufl., 139 S., Forschungsprojekt des Bayerischen Staatsministeriums für Landesentwicklung und Umweltfragen (Hrsg.), München.
- RONDEAUX, G., STEVEN, M. & BARET, F., 1996: Optimization of Soil-Adjusted Vegetation Indices. – Remote Sensing of Environment, **55** (2): 95–107.
- ZARCO, P.J., 1998: Optical Indices as Bioindicators of Forest Sustainability, Research Evaluation Course (REC) Report Number 1, May 4th–5th, York University Toronto.
- ZARCO-TEJADA, P.J. & MILLER, J.R., 1999: Optical Indices as Bioindicators of Forest Condition from Hyperspectral CASI data, presented at the 19th Symposium of the European Association of Remote Sensing Laboratories (EAR-SeL), Valladolid (Spain).

Anschrift der Autorin:

Dipl.-Ing. KATHARINA DREXEL
 Althöhensteigstr. 1
 D-83071 Stephanskirchen
 Tel.: 0174-88 11 267 mobil
 e-mail: kjd2000de@yahoo.de

Manuskript eingereicht: April 2003
 Angenommen: Juni 2003