

## Möglichkeiten und Grenzen der fernerkundlichen Bestimmung biophysikalischer Vegetationsparameter mittels physikalisch basierter Reflexionsmodelle

CLEMENT ATZBERGER, Trier

**Keywords:** remote sensing, vegetation characteristics, reflectance model, model inversion, ill-posed problem, object-based modeling, artificial neural nets

**Zusammenfassung:** Mit dem vorliegenden Artikel soll ein systematischer Überblick über die Möglichkeiten und Grenzen physikalisch basierter Reflexionsmodelle bei der fernerkundlichen Abschätzung biophysikalischer Vegetationsparameter gegeben werden. Dabei wird ein besonderes Augenmerk auf das so genannte „ill-posed“ Problem gelegt. Dieser Begriff beschreibt die Tatsache, dass sehr unterschiedliche Modellparametrisierungen zu mehr oder weniger identischen Reflexionssignaturen führen können. Somit sind solche Reflexionssignaturen auch nicht mehr eindeutig einer einzigen Parameterkombination zuzuweisen. Entsprechende Fehlschätzungen in den biophysikalischen Vegetationsparametern sind die Folge. Nach einer allgemeinen Einführung zur fernerkundlichen Quantifizierung biophysikalischer Vegetationsparameter wird zunächst die Notwendigkeit einer physikalisch basierten Reflexionsmodellierung dargelegt. Es folgt eine eingehende Illustration des „ill-posed“ Problems. Nach einer kurzen Diskussion der bisherigen Lösungsstrategien wird dann eine vom Autor selbst entwickelte Inversionsmethode zur Schätzung der biophysikalischen Vegetationsparameter vorgestellt. Sie berücksichtigt simultan zur eigentlichen Pixelsignatur auch die so genannte Objektsignatur. Der dadurch mögliche Genauigkeitsgewinn wird mit Hilfe synthetischer Datensätze belegt.

**Summary:** *Potentials and limitations of physically based reflectance models in the retrieval of biophysical vegetation characteristics.* This article presents a systematic overview of physically based reflectance models for the retrieval of biophysical canopy variables. A special attention is given to the so-called “ill-posed” problem, describing the fact that quite different model parameterisations can yield almost identical reflectance spectra. Therefore, estimation of canopy variables can be highly erroneous. After the presentation of traditional strategies, this article focuses on the description of a new inversion methodology. The so-called object based model inversion simultaneously considers the pixel signature and the spectral signature of adjoining pixels belonging to the same image object. The approach is validated on synthetic data and results are presented.

---

### 1 Fernerkundliche Quantifizierung biophysikalischer Vegetationsparameter

Flächendeckende und räumlich detaillierte Informationen über die raumzeitliche Ausprägung biophysikalischer Vegetationsparameter wie Blattflächenindex (LAI;  $m^2$

$m^{-2}$ ), Blattchlorophyll- (Cab;  $\mu g cm^{-2}$ ) und Blattwassergehalt (Cw; cm) werden in den verschiedensten Anwendungsbereichen benötigt. So werden beispielsweise im so genannten „precision farming“, Dünge- und Pflanzenschutzmittel räumlich differenziert aufgebracht, wobei sowohl der aktuelle Wachstumszustand der Kulturpflanze, als

auch die jeweiligen Standortsbedingungen, berücksichtigt werden (SCHUELLER 1992). In der Forstwirtschaft ermöglichen Informationen über Struktur, Zusammensetzung und Vitalität der Bestände eine nachhaltigere Bewirtschaftung (FRANKLIN 2001). Eine räumliche differenzierte Parametrisierung prozessorientierter Modelle ist zur Abschätzung regionaler Stoff- und Energieflüsse notwendig (KIMBALL et al. 2000).

Fernerkundung kann zu den genannten Themenfeldern einen Beitrag leisten, da die gesuchten biophysikalischen Parameter die Spektralsignatur der Vegetationsbestände steuern und damit prinzipiell einer fernerkundlichen Kartierung zugänglich sind (GUYOT et al. 1989, BARET 1991, CURRAN 1994, DANSON & MORAN et al. 1997, BARET et al. 2000). Wie zu zeigen sein wird, ist dies jedoch kein triviales Unterfangen. Dies hängt vor allem damit zusammen, dass eine Vielzahl von (biophysikalischen) Parametern ( $V$ ), sowie mehr oder weniger variablen Randbedingungen ( $\theta$ ), das Reflexionsspektrum ( $\rho_\lambda$ ) beeinflussen:

$$\rho_\lambda = f(V_1, \dots, V_n, \theta) \quad (1)$$

Um aus den gemessenen Reflexionsspektren ( $\rho_\lambda$ ), die gesuchten (biophysikalischen) Parameter ( $V$ ) abzuleiten, können zwei Vorgehensweisen gewählt werden: (i) empirisch-statistische Verfahren, und (ii) Inversion physikalisch basierter Modelle.

### 1.1 Empirisch-statistische Verfahren

Zur fernerkundlichen Kartierung der gesuchten biophysikalischen Vegetationsparameter wurden zunächst empirisch-statistische Verfahren entwickelt (s.a. JARMER et al., 2003; dieses Heft). Bei diesen Verfahren werden zuerst mit Hilfe geeigneter Geländekampagnen Transferfunktionen zwischen den zu kartierenden biophysikalischen Parametern ( $V$ ) und den Spektraldaten ( $\rho_\lambda$ ) erstellt. Nach deren Kalibration können diese dann auf die Fernerkundungsszenen angewandt werden.

Diese Vorgehensweise ist relativ einfach, stößt aber immer dann an ihre Grenzen,

wenn die kalibrierten Transferfunktionen auf Daten mit abweichenden (Rand)Bedingungen angewandt werden. Daher lassen sich solche empirisch-statistischen Methoden generell nur schwer auf andere Regionen und Zeitpunkte übertragen (CURRAN 1994, TREITZ & HOWARTH 1999).

### 1.2 Physikalisch basierte Reflexionsmodellierung

Wegen der genannten Unzulänglichkeiten empirisch-statistischer Verfahren wurden seit den 80er Jahren erhebliche Anstrengungen unternommen, physikalisch basierte Transferfunktionen zu entwickeln – so genannte Strahlungstransfermodelle bzw. Reflexionsmodelle. Umfangreiche Darstellungen solcher Modelle, wie auch verschiedener Modellierungsstrategien, finden sich u. a. in GOEL (1987) und MYNENI & ROSS (1991). Im weiteren Verlauf des Textes wird sich ausschließlich auf solche Reflexionsmodelle bezogen.

Physikalisch basierte Reflexionsmodelle berechnen, auf der Grundlage physikalischer Prinzipien, die spektrale bi-direktionelle Reflexion von Vegetationsbeständen (Eq. 1), wobei vier Modellierungsstrategien unterschieden werden (GOEL 1987):

- geometrisch-optische Reflexionsmodelle (z. B. LI & STRAHLER 1986, CHEN & LEBLANC 1997)
- analytische Reflexionsmodelle (z. B. VERHOEF 1984, JACQUEMOUD et al. 1995)
- Kopplungen aus geometrisch-optischen und analytischen Reflexionsmodellen (z. B. ATZBERGER 2000, GARCIA-HARO & SOMMER 2002)
- Ray-Tracing Modelle (z. B. GASTELLU-ETCHEGORRY et al. 1996, NORTH 1996)

Geometrisch-optische Reflexionsmodelle werden hauptsächlich für forstliche Anwendungen eingesetzt, weil dort die Ausbildung von Baumkronen die Berechnung von Schattenwurf sinnvoll erscheinen lässt. Analytische Reflexionsmodelle approximieren den Bestand dagegen als ein „turbid medium“. Solche Bedingungen können typischerweise in landwirtschaftlichen Kultur-

pflanzenbeständen erwartet werden. Kombinationen aus den beiden vorstehend genannten Modelltypen berücksichtigen, dass auch Baumkronen nicht völlig opak sind und stellen somit eine Weiterentwicklung der geometrisch-optischen Modelle dar. Ray-Tracing Modelle sind im Prinzip am exaktesten, da sie den kompletten Gang der Photonen im Bestandsraum nachvollziehen. Die Berücksichtigung orts- und richtungsabhängiger Streu- und Absorptionsprozesse setzt allerdings eine komplette Beschreibung der 3-dimensionalen Bestandsstruktur voraus. Anwendungen dieses Modelltyps sind entsprechend schwierig zu parametrisieren und zudem sehr rechenzeitaufwendig

Auf weitere charakteristische Merkmale der verschiedenen Modelltypen kann hier aus Platzgründen nicht eingegangen werden. Es bleibt jedoch festzuhalten, dass alle Reflexionsmodelle lediglich die spektrale Reflexion eines Vegetationsbestandes ( $\rho_i$ ) für einen spezifizierten Parametersatz ( $V, \theta$ ) berechnen. Um mit Hilfe von physikalisch basierten Reflexionsmodellen die gewünschten biophysikalischen Parameter abzuleiten, sind solche Modelle zu invertieren. Dies ist allerdings wegen der Vielzahl der Parameter auf analytischem Wege nicht möglich. Zur Invertierung von Reflexionsmodellen wurden daher verschiedene Verfahren entwickelt (KIMES et al. 2000):

- „look-up-table“ Verfahren (z. B. COMBAL & BARET 2001, COMBAL et al. 2002)
- iterative numerische Minimierungen (z. B. ATZBERGER 1995, JACQUEMOUD et al. 1995)
- künstliche Neuronale Netze (z. B. GONG et al. 1999, UDELHOVEN et al. 2000)
- Bildung so genannter „predictive equations“ (z. B. BROGE & LEBLANC 2000, SCHLERF & ATZBERGER 2002)

Bei der numerisch-iterativen Inversion handelt es sich um ein klassisches Optimierungsproblem. Bei diesem wird ein Minimierungskriterium (meistens die aufsummierten quadrierten Residuen zwischen gemessener und simulierter Spektralsignatur) durch die iterative Anpassung der Modellparameter (i. e.  $V_1, \dots, V_n$ ) minimiert, wobei die

Randbedingungen ( $\theta$ ) zuvor zu spezifizieren sind. Der zum Minimum führende Parametersatz wird dann als Ergebnis ausgegeben.

Diese rechenzeitaufwendige Optimierung kann durch die Verwendung so genannter Look-up-tables (LUT) vermieden werden. Hier wird das Reflexionsmodell lediglich dazu verwendet, eine große Anzahl von Spektren mit unterschiedlicher Parameterkombination zu simulieren. Diese werden dann gemeinsam in einer Tabelle abgelegt. Ein zu invertierendes Reflexionsspektrum muss dann nur noch mit den im LUT abgelegten Spektren abgeglichen werden. Der zum LUT-Spektrum mit den geringsten Abweichungen gehörige Parametersatz stellt dann das Ergebnis dar. Dieses prinzipiell einfache und elegante Verfahren stößt allerdings dann an seine Grenzen, wenn Reflexionsmodelle verwendet werden, die eine Vielzahl von Parametern aufweisen, deren spezifische Einflüsse in kleinen Schrittweiten Berücksichtigung finden sollen.

Eine dritte Herangehensweise besteht in der Nutzung so genannter künstlicher neuronaler Netze. Ähnlich wie bei den LUT Verfahren wird zunächst mit Hilfe des Reflexionsmodells eine große Anzahl von Spektren simuliert. Spektren und dazugehörige Parametersätze werden dann in einem Trainingsschritt dazu verwendet, die Koeffizienten des künstlichen neuronalen Netzes so anzupassen, dass aus einem gegebenen Reflexionsspektrum die biophysikalischen Parameter errechnet werden können. Künstliche neuronale Netze bieten gegenüber den iterativen Optimierungsverfahren den Vorteil, dass sie nach erfolgtem Training sehr schnell sind. Sie eignen sich daher auch hervorragend für die Prozessierung ganzer Fernerkundungsszenen. Im Vergleich zum empirisch-statistischen Vorgehen ist weiterhin positiv hervorzuheben, dass neuronale Netze auch nicht-lineare Beziehungen zwischen den Reflexionsswerten und den biophysikalischen Parametern berücksichtigen, ohne dass diese explizit formuliert werden müssten (KIMES et al. 1998). Nachteilig ist allerdings die relativ zeitaufwendige Trainingsphase.

Die Methodik so genannter „predictive equations“ ähnelt sehr stark den empirisch-statistischen Verfahren. Der entscheidende Unterschied besteht darin, dass abhängige und unabhängige Variablen nicht mehr experimentell gewonnen werden, sondern mit Hilfe der physikalisch basierten Reflexionsmodelle synthetisiert werden. Im Gegensatz zu den künstlichen neuronalen Netzen ist vom Auswerter allerdings explizit festzulegen, welche Art der Beziehung unterstellt werden soll.

## 2 Das „ill-posed“ Problem

Das grundlegende Problem bei der Arbeit mit Reflexionsmodellen besteht darin, dass sehr unterschiedliche Parameterkombinationen zu mehr oder weniger identischen Reflexionsspektren führen können (VERSTRAETE et al. 1996, BARET & FOURTY 1997). Diese Problematik gilt unabhängig von der gewählten Modellierungs- und Invertierungsstrategie. Damit können die gesuchten biophysikalischen Parameter auch nicht mehr zweifelsfrei aus den aufgezeichneten Spektraldaten abgeleitet werden. Man spricht hier im Sinne von COMBAL et al. (2002) vom so genannten „ill-posed“ Problem.

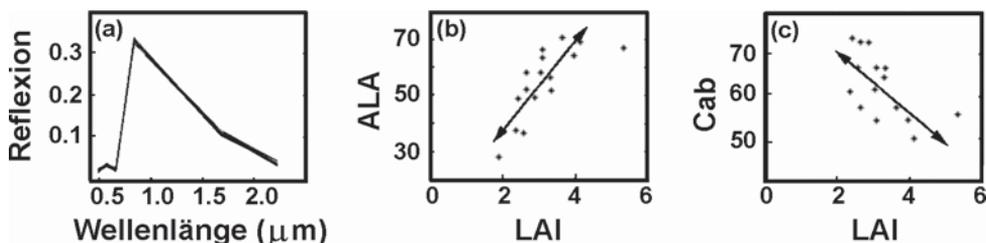
Zur Illustration dieses Sachverhaltes sind in Abb. 1a sechzehn mehr oder weniger identische Reflexionsspektren in den reflektiven TM-Kanälen dargestellt. Die aus sehr unterschiedlichen Parameterkombinationen resultierenden Spektren sind visuell

kaum noch zu unterscheiden. Die Mehrdeutigkeit der Reflexionssignatur ist augenscheinlich darauf zurückzuführen ist, dass sich die verschiedenen Parameter gegenseitig kompensieren (Abb. 1bc). So kann eine Zunahme des Blatthaltungswinkels (ALA) dadurch ausgeglichen werden, dass der LAI zunimmt und der Blattchlorophyllgehalt (Cab) abnimmt.

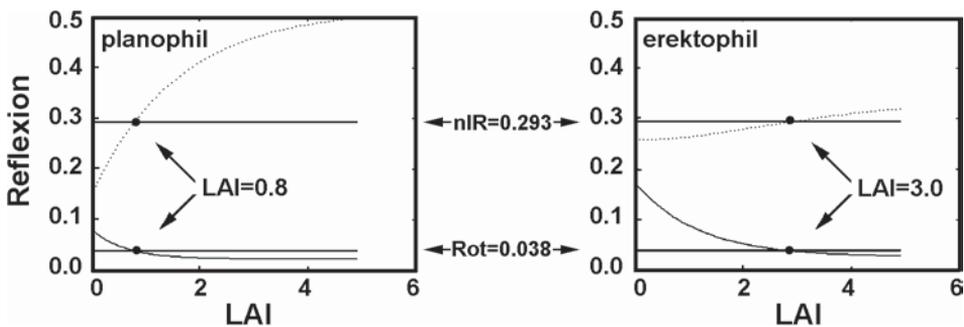
In Abb. 2 ist die simulierte Bestandsreflexion (Rot und nIR) zweier Bestände als Funktion des LAIs dargestellt. Der im linken Teil der Abbildung dargestellte Bestand weist eine planophile Blatthaltung auf, der andere dagegen eine erektophile Blatthaltung. Eine (exemplarische) Reflexion von 0.031 (Rot) bzw. 0.308 (nIR) entspricht danach beim planophilen Bestand einem LAI von nur 0.8, hingegen beim erektophilen Bestand einem LAI von 3.0. Dies hat gravierende Fehlschätzungen des LAIs zur Folge, wenn der Blatthaltungswinkel eines gegebenen Pixels falsch eingeschätzt wird.

Bislang wurden zur Lösung des „ill-posed“ Problems drei Strategien vorgeschlagen:

- Berücksichtigung externer *a priori*-Informationen (JACQUEMOUD 1993, COMBAL et al. 2002, COMBAL & BARET 2001)
- Nutzung multi-temporalen Aufnahmen zur Generierung und Berücksichtigung von *a priori* Information (KOETZ 2001, POILVÉ 2002)
- Assimilation der (multi-temporalen) Bestandsreflexion in prozessorientierten Modellen (DELÉCOLLE et al. 1992, MOULIN et al. 1998, ATZBERGER et al. 2001)



**Abb. 1:** (a) Zur Illustration des „ill-posed“ Problems sind 16 simulierte Reflexionsspektren in der spektralen Auflösung des Landsat TM Sensors dargestellt. Obwohl die den Spektren zugrunde liegenden Parameter weite Wertebereiche umfassen, sind die Spektren visuell kaum noch zu unterscheiden. (b) und (c): Die „ill-posed“ Problematik resultiert aus der Tatsache, dass sich einige Parameter in ihren Effekten gegenseitig kompensieren. Alle Simulationen wurden mit Hilfe des SPECAN Modells (JACQUEMOUD et al. 1995) durchgeführt.



**Abb. 2:** Simulierte Abhängigkeit der Rot- (durchgezogene Linie) und nIR-Reflexion (gepunktete Linie) als Funktion des LAIs für einen planophilen Bestand (links), sowie einen erectophilen Bestand (rechts). Ebenfalls dargestellt ist die Kombination aus Rot und nIR-Reflexion, die in diesem speziellen Fall zu Fehlschätzungen des LAIs führen würde. Den Simulationen liegt das SPECAN Modell (JACQUEMOUD et al., 1995) zugrunde ( $\theta_v = 0^\circ$ ,  $\theta_z = 40^\circ$ ,  $hot = 0.001$ ,  $N = 2$ ,  $C_m = 0.01$ ,  $skyl = 0.1$ ,  $psoil(nIR) = 0.051 + 1.2 \cdot \rho_{soil}(Rot)$ ). Planophiler Bestand:  $ALA = 30^\circ$ ,  $Cab = 75 \mu\text{g}/\text{cm}^2$ ,  $psoil(Rot) = 0.081$ . Erectophiler Bestand:  $ALA = 70^\circ$ ,  $Cab = 25 \mu\text{g}/\text{cm}^2$ ,  $psoil(Rot) = 0.172$ .

Die Berücksichtigung von externer *a priori* Information bringt spürbare Verbesserungen in der Schätzgenauigkeit, setzt allerdings voraus, dass die benötigten Informationen (z. B. Blatthaltungswinkel im jeweiligen Pixel) tatsächlich für jedes Pixel zur Verfügung stehen.

Die Stetigkeit der LAI-Entwicklung im Entwicklungszyklus der Pflanze wird bei der bildgestützten Generierung von *a priori* Information in Wert gesetzt. Dabei wird der LAI zunächst mit klassischen Verfahren für jeden einzelnen Aufnahmezeitpunkt geschätzt. Die geschätzten LAIs werden dann als Funktion der Zeit durch eine semi-empirische Funktion gefittet. Die so gefitteten LAIs zu den einzelnen Aufnahmezeitpunkten stellen dann in einem zweiten Schritt *a priori* Werte dar, mit denen die Modellinversion wiederholt wird. Der iterative Prozess wird so lange fortgesetzt, bis eine Stabilisierung der Ergebnisse erreicht ist.

Die Assimilation von Fernerkundungsdaten in prozessorientierte Modelle verzichtet gänzlich auf die Inversion des Reflexionsmodells. Vielmehr werden Prozess- und Reflexionsmodelle so miteinander gekoppelt, dass mit Hilfe der (klimatischen) Antriebsvariablen LAI-Entwicklungen simuliert werden, die wiederum die Berechnung temporaler Reflexionsprofile ermöglichen. Aufgezeichnete Reflexionsspektren zu einem

oder mehreren Zeitpunkten werden dann in einem iterativen Verfahren dazu verwendet, Parameter des gekoppelten Prozess-/Reflexionsmodells anzupassen, um so zu einer verbesserten Beschreibung der Energie- und Stoffflüsse zu gelangen.

Mit der vorliegenden Publikation soll ein weiterer, vom Autor selbst entwickelter Lösungsansatz, für die „ill-posed“ Problematik präsentiert werden (ATZBERGER 2002). Die Methodik berücksichtigt dabei neben der eigentlichen Pixelsignatur auch die Spektralinformation räumlich angrenzender Pixel, um die gesuchten biophysikalischen Parameter zu bestimmen.

### 3 Objektbasierte Reflexionsmodellierung und Modellinversion

Der objektbasierte Inversionsansatz berücksichtigt simultan zur eigentlichen Pixelsignatur die Spektralinformation der angrenzenden Pixel (d. h. die sogenannte „Objektsignatur“) (ATZBERGER 2002). Zur Berechnung der Objektsignatur müssen die Fernerkundungsdaten daher zunächst segmentiert werden. Dabei werden Bildobjekte ausgegrenzt, die in sich gesehen relativ homogen sind. Eine solche Homogenität ist dann gegeben, wenn die Objekte mit der gleichen Kultur bestockt sind und sich in

einer ähnlichen Entwicklungsphase befinden. Die Segmentierung kann entweder durch spezielle Segmentierungssoftware erfolgen oder auf der Basis eines GIS-Layers, der z. B. die einzelnen landwirtschaftlichen Schläge umfasst.

Nach der Segmentierung werden aus den Spektralwerten der einzelnen Pixel des jeweiligen Objektes die spektralen Objektsignaturen berechnet. Dabei werden neben den spektralen Mittelwerten und Standardabweichungen auch die spektralen Interdependenzen berücksichtigt (u. a. Steigung, y-Achsenabschnitt und  $R^2$  zwischen den einzelnen Spektralkanälen) (Absatz 3.1).

### 3.1 Objektsignaturen im Merkmalsraum Rot-nIR

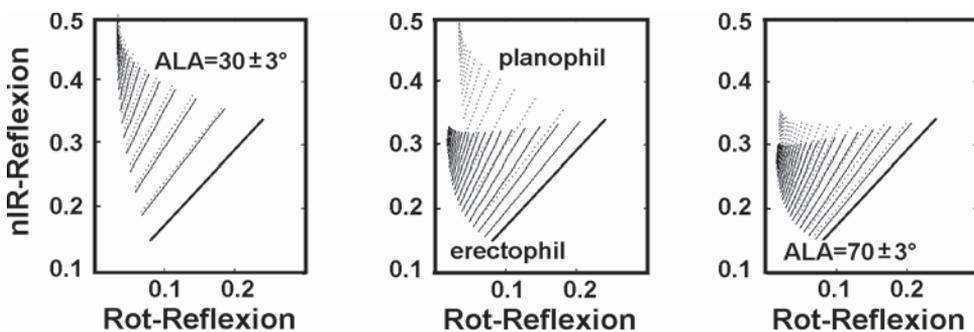
Um zu verdeutlichen, warum die Objektsignatur eine über die eigentliche Pixelsignatur hinausgehende Information enthält, sind in Abb. 3 simulierte LAI-Isolinien im 2-dimensionalen Merkmalsraum (Rot und nIR) dargestellt. Der linke Teil der Abbildung enthält LAI-Isolinien für planophile Bestände ( $ALA = 30 \pm 3^\circ$ ), der rechte Teil für erektophile Bestände ( $ALA = 70 \pm 3^\circ$ ). Im mittleren Teil sind LAI-Isolinien für planophile und erektophile Bestände gemeinsam dargestellt.

Es ist gut zu erkennen, dass im Überschneidungsbereich zwischen planophilen

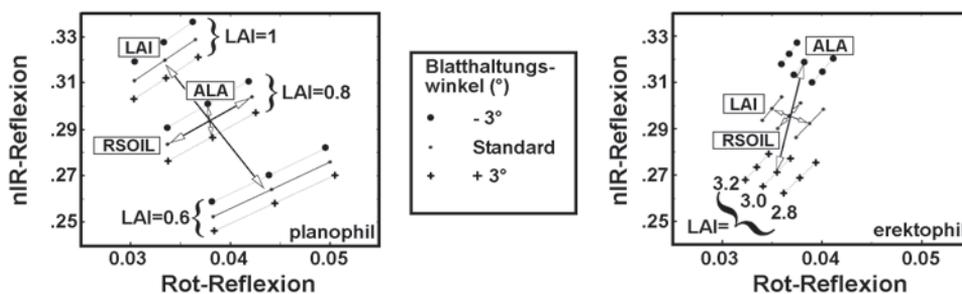
und erektophilen LAI-Isolinien Probleme bei der klassischen Invertierung zu erwarten sind, da eine gegebene Kombination aus Rot und nIR-Reflexion je nach Blatthaltungswinkel mit unterschiedlichen LAIs und Bodenheiligkeiten erreicht wird.

Geht man dagegen davon aus, dass zwei ansonsten (spektral) nicht unterscheidbare Pixel zu zwei Grundgesamtheiten plano- bzw. erektophiler Pixel gehören, wird deutlich, warum die Objektsignatur einen Informationsgewinn beinhaltet. Variationen der biophysikalischen Bestandsparameter innerhalb eines landwirtschaftlichen Schlages werden sich nämlich in charakteristischen Verschiebungsvektoren widerspiegeln, die sich deutlich zwischen plano- und erektophilen Beständen unterscheiden (Abb. 4 u. Abb. 5). So weisen (für den in Abb. 2 illustrierten Fall) erektophile Bestände eine (schwache) positive Korrelation zwischen Rot und nIR Reflexion auf, während die planophilen Bestände eine (deutliche) negative Korrelation zeigen (Abb. 5). Damit sind Enge ( $R^2$ ) und Richtung (Steigung und y-Achsenabschnitt) der Clusterhauptachse informationsbeinhaltende Objektcharakteristika.

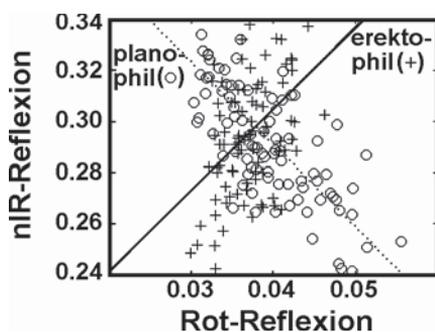
In Abhängigkeit vom (mittleren) Blatthaltungswinkel der landwirtschaftlichen Schläge variieren auch die (kanalspezifischen) Standardabweichungen sowie die



**Abb. 3:** Simulierte LAI-Isolinien im 2-dimensionalen Merkmalsraum aus Rot- und nIR-Reflexion für planophile und erektophile Bestände. Die LAI-Isolinien nehmen zwischen dem unbedeckten Boden ( $LAI = 0$ ; fette Linie) und  $LAI = 5$  mit Inkrementen von 0.2 LAI-Einheiten zu ( $Cab = 40 \mu g cm^{-2}$ ; alle anderen Parameter wie in Abb. 2). Um zu verdeutlichen, wie sich bestandsinterne Variationen des Blatthaltungswinkels auf die Reflexionssignatur auswirken, sind links die LAI-Isolinien für Blatthaltungswinkel von  $27$  und  $33^\circ$  dargestellt, rechts von  $67$  und  $73^\circ$ .



**Abb. 4:** Entstehung von Objektsignaturen im 2-dimensionalen Merkmalsraum aus Rot- und nIR-Reflexion durch „intra-field“ Variationen wichtiger biophysikalischer Modellparameter. Die Variationen um den in Abb. 2 spezifizierten Parametersatz betragen für den LAI  $\pm 0.2$  Einheiten, für den Blatthaltungswinkel  $\pm 3^\circ$ , und für die Bodenhelligkeit  $\pm 0.01$ . Eingetragen sind jeweils drei LAI-Isolinien für die Standard-Blatthaltung (durchgezogene Linien), sowie korrespondierende LAI-Isolinien, die sich aus einer Verminderung (●) bzw. Erhöhung (+) des jeweiligen Blatthaltungswinkels ergeben. Eingezeichnet sind die jeweiligen Verschiebungsvektoren, die aus den spezifizierten „intra-field“ Variationen resultieren.

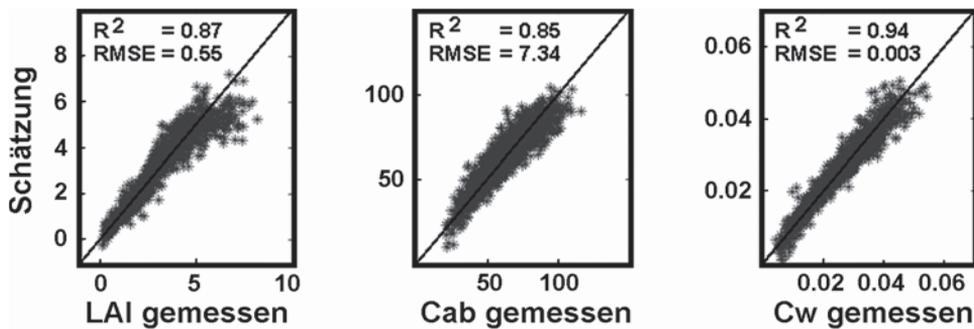


**Abb. 5:** Resultierende Objektsignaturen im 2-dimensionalen Merkmalsraum aus Rot- und nIR-Reflexion für planophile (o) und erektophile Bestände (+) bei zufallsgenerierter Variation von LAI ( $\pm 0.2$ ), ALA ( $\pm 3^\circ$ ), Cab ( $\pm 2 \mu\text{g cm}^{-2}$ ) und Bodenhelligkeit ( $\pm 0.01$ ) um den in Abb. 2 spezifizierten Parametersatz.

Schiefen in den Häufigkeitsverteilungen der Reflexionswerte (hier nicht gezeigt). Ähnliche Beziehungen lassen sich auch für andere Kanalkombinationen darstellen, können hier allerdings aus Platzgründen nicht weiter besprochen werden. Es lag daher nahe, solche Muster mit Hilfe künstlicher neuronaler Netze zu trainieren und für die Modellinversion heranzuziehen (Absatz 3.2).

### 3.2 Ergebnisse des Objekt basierten Invertierungsansatzes

Um einen Vergleichsmaßstab zu haben, wurden die Ergebnisse der vorgeschlagenen objektbasierten Invertierung mit denen der klassischen (pixelbasierten) Invertierungsstrategie verglichen. Zur optimalen Kontrolle aller Parameter und Einflussfaktoren wurde dazu zunächst mit Hilfe etablierter Reflexionsmodelle (JACQUEMOUD et al. 1995) ein spezieller synthetischer Datensatz in den 6 reflektiven TM-Kanälen generiert (100.000 Objekte mit jeweils 25 Pixeln charakterisiert durch zufallsgenerierte Parameterverteilungen). Es wurde großen Wert darauf gelegt, dass die Modellparameter sehr große Wertebereiche umfassen, um eine Anwendung der Methodik auf den verschiedensten Kulturen gewährleisten zu können. Aus den jeweils 25 Pixeln pro Objekt wurden dann die Objektsignaturen berechnet (Absatz 3.1) und jeweils einem Pixel zugeordnet. Die verbleibenden 24 Pixel wurden nicht weiter berücksichtigt. Die vergleichende Analyse bestand dann darin, künstliche neuronale Netze mit und ohne diese Objektsignatur zu trainieren (nobs = 70.000) und auf einem unabhängigen Validierungsdatensatz (nobs = 30.000) zu testen (bei ansonsten identischen Bedingungen). Weitere Details finden sich in ATZBERGER (2002).



**Abb. 6:** Tatsächliche gegen geschätzte Bestandsparameter (Blattflächenindex, Blattchlorophyllgehalt und Blattwassergehalt) bei Verwendung des objektbasierten Inversionsverfahrens (synthetischer Validierungsdatensatz in der spektralen Auflösung des Landsat-TM; nobs = 30.000). Zur Umsetzung des objektbasierten Inversionsansatzes wurden künstliche neuronale Netze mit 10 Neuronen im verdeckten Layer verwendet. Zu Illustrationsszwecken ist lediglich jeder 10te Datenpunkt dargestellt (ATZBERGER 2002).

**Tab. 1:** Statistische Kenngrößen zwischen tatsächlichen und geschätzten Bestandsparametern für den objektbasierten und den pixelbasierten Inversionsansatz unter Verwendung eines synthetischen Validierungsdatensatzes in der spektralen Auflösung des Landsat-TM und künstlicher neuronaler Netze. Der T-Wert ähnelt dem  $R^2$ , mit dem Unterschied, dass er die Abweichungen von der 1 : 1 Linie misst.  $\Delta$  ist die Differenz zwischen den Mittelwerten aus tatsächlichen und geschätzten Variablen (nobs = 30.000) (ATZBERGER, 2002).

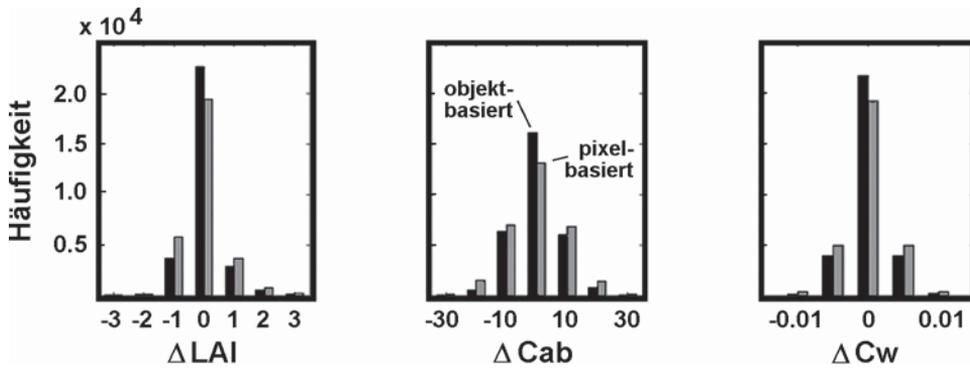
	objektbasiert			pixelbasiert		
	LAI	Cab	Cw	LAI	Cab	Cw
$R^2$	0.87	0.85	0.94	0.81	0.78	0.91
Steigung	0.869	0.854	0.937	0.812	0.780	0.909
y-Achsenab.	0.43	9.09	0.002	0.62	13.77	0.002
RMSE	0.55	7.34	0.0026	0.66	9.04	0.0030
PRMSE (%)	6.3	7.4	4.8	7.6	9.2	5.7
T-Wert	0.87	0.85	0.94	0.81	0.78	0.91
$\Delta$	0.004	-0.008	0.000	0.012	0.024	0.000

Aus der graphischen Gegenüberstellung zwischen tatsächlichen und geschätzten Vegetationsparametern des unabhängigen Validierungsdatensatzes wird die Brauchbarkeit des objektbasierten Inversionsansatzes deutlich (Abb. 6). Es gelingt sowohl strukturelle Größen wie den LAI mit einer hohen Genauigkeit zu schätzen ( $R^2 = 0.87$ ), als auch biochemische Größen wie den Blattchlorophyll- und Blattwassergehalt ( $R^2 = 0.85$  bzw.  $0.94$ ) (Tab. 1). Obwohl die Analysen sehr weite Wertebereiche umfassen sind noch keine Sättigungseffekte zu erkennen. Relative RMSE liegen für die drei untersuchten biophysikalischen Vegetationsparameter zwischen 5 und 8% (Tab. 1). Die Abweichungen zwischen tatsächlichen und

geschätzten biophysikalischen Vegetationsparametern sind dabei bei dem objektbasierten Ansatz deutlich enger um den 0-Wert zentriert, als beim herkömmlichen pixelbasierten Inversionsansatz (Abb. 7). Auch andere statistische Kenngrößen in Tab. 1 belegen den durch den objektbasierten Inversionsansatz erzielten Genauigkeitserfolg.

#### 4 Zusammenfassung

Es konnte gezeigt werden, dass die Verwendung physikalisch basierter Reflexionsmodelle Vorteile gegenüber den empirisch-statistischen Verfahren bietet. Gleichzeitig hat die Illustration des so genannten „ill-posed“ Problems aber auch deutlich gemacht, wo



**Abb. 7:** Abweichungen zwischen tatsächlichen und geschätzten Bestandsparametern mit/ohne Verwendung der Objektsignaturen (synthetischer Validierungsdatensatz in der spektralen Auflösung des Landsat-TM) (ATZBERGER 2002).

selbst physikalisch basierte Reflexionsmodelle an ihre Grenzen stoßen.

Die bislang zur Lösung des „ill-posed“ Problems vorgeschlagenen Ansätze setzen allesamt Informationen voraus, die entweder extern beigesteuert werden müssen oder aber aus multi-temporalen Aufnahmesequenzen abzuleiten sind. Um davon unabhängig zu werden, wurde vom Autor ein Ansatz entwickelt, der die benötigten Informationen aus dem zu bearbeitenden Bild selbst extrahiert. Mit Hilfe der so genannten Objektsignatur ließen sich biophysikalische Vegetationsparameter wie Blattflächenindex, Blattchlorophyll- und Blattwassergehalt mit höheren Genauigkeiten schätzen, als beim pixelbasierten Ansatz ( $r^2$  zwischen 0.85 und 0.94). Die prozentualen RMSE des unabhängigen Testdatensatzes lagen in allen Fällen unter 8%. Weitere Untersuchungen werden sich nun darauf konzentrieren, nachzuweisen, dass der vorgeschlagene Ansatz weniger anfällig für Sensorrauschen ist, als der klassische Invertierungsansatz. Zudem sind die besonders aussagekräftigen Objektsignaturen zu bestimmen. Daneben soll die vorgeschlagene Strategie auch auf forstliche Fragestellungen ausgeweitet werden.

### Danksagung

Ich danke FRÉDÉRIC BARET und STÉPHANE JACQUEMOUD für die Bereitstellung der verwendeten Reflexionsmodelle. Dank gebührt

MARTIN SCHLERF und THOMAS UDELHOVEN für die Korrektur des Manuskriptes. Meiner Frau MAGDA CHELFAOUI danke ich für die gewährte Unterstützung.

### Literatur

- ATZBERGER, C., 1995: Accuracy of multitemporal LAI estimates in winter wheat using analytical (PROSPECT + SAIL) and semiempirical reflectance models. – In: GUYOT (Ed.): Assessment of remote sensing tools for the estimation of photosynthesis and primary production. Present and future potential. – 423–428, Montpellier, Frankreich.
- ATZBERGER, C., 2000: INFORM: Ein invertierbares Forstreflexionsmodell zur fernerkundlichen Bestimmung biophysikalischer Größen. – In: ALBERTZ, J. (Ed.): Photogrammetrie und Fernerkundung. Neue Sensoren – Neue Anwendungen. – Publikationen der Deutschen Gesellschaft für Photogrammetrie und Fernerkundung, **8**: 163–173.
- ATZBERGER, C., 2002: Object-based retrieval of structural and biochemical canopy characteristics using SAIL + PROSPECT canopy reflectance model: A numerical experiment. – In: SOBRIANO (Ed.): Recent advances in quantitative remote sensing. – Valencia, Spanien, in Druck.
- ATZBERGER, C., GUÉRIF, M. & DELÉCOLLE, R., 2001: The use of GRAMI crop growth model and SPOT data for biomass estimations in winter wheat. – In: LEROY (Ed.): Physical measurements and signatures in remote sensing. – 705–711, Balkema, Aussois.
- BARET, F., 1991: Vegetation canopy reflectance: Factors of variation and application for agri-

- culture. – In: HUNT (Ed.): Physical measurements and signatures in remote sensing. – 145–167, France.
- BARET, F. & FOURTY, T., 1997: The limits of a robust estimation of canopy biochemistry. – In: GUYOT & PHULPIN (Ed.): Physical measurements and signatures in remote sensing. – 413–420, Balkema, Rotterdam.
- BARET, F., WEISS, M., TROUFLEAU, D., PREVOT, L. & COMBAL, B., 2000: Maximum information exploitation for canopy characterisation by remote sensing. – *Aspects of Applied Biology* 60 – Remote sensing in agriculture: 71–82.
- BROGE, N.H. & LEBLANC, E., 2000: Comparing predictive power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. – *Remote Sensing of Environment*, **76**: 156–172.
- CHEN, J. & LEBLANC, S., 1997: A four-scale bidirectional reflectance model based on canopy architecture. – *IEEE Trans. Geoscience and Remote Sensing*, GE- **35** (5): 1316–1337.
- COMBAL, B. & BARET, F., 2001: Estimation of chlorophyll content from remote sensing observations in the solar domain. – In: LEROY (Ed.): Physical measurements and signatures in remote sensing. – 461–471, Balkema, Aussois.
- COMBAL, B., BARET, F., WEISS, M.; TRUBUIL, A., MACÉ, D., PRAGNÈRE, A., MYNENI, R., KNYAZIKHIN, Y. & WANG, L., 2002: Retrieval of canopy biophysical variables from bidirectional reflectance using prior information to solve the ill-posed inverse problem. – *Remote Sensing of Environment*, **84**: 1–15.
- CURRAN, P.J., 1994: Imaging spectrometry. – *Progress in Physical Geography*, **18**(2): 247–266.
- DANSON, F.M. & CURRAN, P.J., 1993: Factors affecting the remotely sensed response of coniferous forest plantations. – *Remote Sensing of Environment*, **43**: 55–65.
- DELÉCOLLE, R., MAAS, S., GUÉRIF, M. & BARET, F., 1992: Remote sensing and crop production models: Present trends. – *ISPRS Journal of Photogrammetry and Remote Sensing*, **47**: 145–161.
- FRANKLIN, S.E., 2001: Remote sensing for sustainable forest management. – Lewis Publishers, Boca Raton.
- GARCIA-HARO, F.J. & SOMMER, S., 2002: A fast canopy reflectance model to simulate realistic remote sensing scenarios. – *Remote Sensing of Environment*, **81**: 205–227.
- GASTELLU-ETCHEGORRY, J.P., DEMAREZ, V., PINEL, V. & ZAGOLSKI, F., 1996: Modeling radiative transfer in heterogeneous 3-D vegetation canopies. – *Remote Sensing of Environment*, **58**: 131–156.
- GOEL, N.S., 1987: Models of vegetation canopy reflectance, their use in estimation of biophysical parameters from reflectance data. – *Remote Sensing Reviews*, **4**: 1–212.
- GONG, P., WANG, D.X. & LIANG, S., 1999: Inverting a canopy reflectance model using neural network. – *International Journal of Remote Sensing*, **20** (1): 111–122.
- GUYOT, G., GUGON, D. & RIOM, J., 1989: Factors affecting the spectral response of forest canopies: A review. – *Geocarto International*, **3**: 43–60.
- JACQUEMOUD, S., 1993: Inversion of the PROSPECT + SAIL canopy reflectance model from AVIRIS equivalent spectra: Theoretical study. – *Remote Sensing of Environment*, **44**: 281–292.
- JACQUEMOUD, S., BARET, F., ANDRIEU, B., DANSON, M. & JAGGARD, K., 1995: Extraction of vegetation biophysical parameters by inversion of the PROSPECT + SAIL models on sugar beet canopy reflectance data. Application to TM and AVIRIS sensors. – *Remote Sensing of Environment*, **52**: 163–172.
- JARMER, T., KOETZ, B. & ATZBERGER, C., 2003: Spektroradiometrische Ableitung biophysikalischer Vegetationsparameter von Weizenbeständen: Vergleichende Untersuchung verschiedener empirisch-statistischer Verfahren. – *Photogrammetrie – Fernerkundung – Geoinformation*, **2003** (1): 43–50 (dieses Heft).
- KIMBALL, J.S., KEYSER, A.R., RUNNING, S.W. & SAATCHI, S.S., 2000: Regional assessment of boreal forest productivity using an ecological process model and remote sensing parameter maps. – *Tree Physiology*, **20**: 761–775.
- KIMES, D.S., KNYAZIKHIN, Y., PRIVETTE, J., ABUEL GASIM, A.A. & GAO, W., 2000: Inversion methods for physically-based models. – *Remote Sensing Reviews*, **18**: 381–439.
- KIMES, D.S., NELSON, R.F., MANRY, M.T. & FUNG, A.K., 1998: Attributes of neural networks for extracting continuous vegetation variables from optical and radar measurements. – *International Journal of Remote Sensing*, **19**: 2639–2663.
- KOETZ, B., 2001: Use of coupled evolution and radiative transfer models to derive biophysical canopy characteristics from multispectral/temporal remote sensing data. – *Diplomarbeit, Universität Trier*, unveröff.
- LI, X. & STRAHLER, A.H., 1986: Geometric-optical bidirectional reflectance modeling of a co-

- nifer forest canopy. – IEEE Trans. Geoscience and Remote Sensing, **GE- 24** (6): 906–919.
- MORAN, S. M., INOUE, Y. & BARNES, E. M., 1997: Opportunities and limitations for image-based remote sensing in precision crop management. – Remote Sensing of Environment, **61**: 319–346.
- MOULIN, S., BONDEAU, A. & DELÉCOLLE, R., 1998: Combining agricultural crop models and satellite observations: From field to regional scales. – International Journal of Remote Sensing, **19** (6): 1021–1036.
- MYNENI, R. B. & ROSS, J. K., 1991: Photon-Vegetation Interactions. – Springer-Verlag, New York.
- NORTH, P. R. J., 1996: Three-dimensional forest light interaction model using a Monte Carlo method. – IEEE Trans. Geoscience and Remote Sensing, **GE 34** (4): 946–956.
- POILVÉ, H., 2002: CROMA: Crop Reflectance Operational Models for Agriculture, Final report. – EC research project EVG1-CT-2000-00027.
- SCHLERF, M. & ATZBERGER, C., 2002: Use of a forest reflectance model for empirical estimation of Norway spruce characteristics from hyperspectral imagery. – In: SOBRINO (Ed.): Recent advances in quantitative remote sensing. – Valencia, Spanien, in Druck.
- SCHUELLER, J. K., 1992: A review and integrating analysis of spatially-variable control of crop production. – Fertilizer Research, **33**: 1–34.
- TREITZ, P. M. & HOWARTH, P. J., 1999: Hyperspectral remote sensing for estimating biophysical parameters of forest ecosystems. – Progress in Physical Geography, **23** (3): 359–390.
- UDELHOVEN, T., ATZBERGER, C. & HILL, J., 2000: Retrieving structural and biochemical forest characteristics using artificial neural networks and physically based reflectance models. – In: BUCHROITHNER (Ed.): A decade of trans-european remote sensing cooperation. – 205–211, Balkema, Dresden.
- VERHOEF, W., 1984: Light scattering by leaf layers with application to canopy reflectance modeling: The SAIL model. – Remote Sensing of Environment, **16**: 125–141.
- VERSTRAETE, M. M., PINTY, B. & MYNENI, R. B., 1996: Potential and limitations of information extraction on the terrestrial biosphere from satellite remote sensing. – Remote Sensing of Environment, **58**: 201–214.

## Anschrift des Autors:

Dr. rer. nat. CLEMENT ATZBERGER, Universität Trier, Abt. Fernerkundung, Behringstraße, D-54286 Trier, Tel.: +49-651-201-4596, Fax: +49-651-201-3815 e-mail: atzberger@feut.de

Manuskript eingereicht: November 2002

Angenommen: November 2002