

**Zeitschrift:** Botanica Helvetica  
**Herausgeber:** Schweizerische Botanische Gesellschaft  
**Band:** 114 (2004)  
**Heft:** 2

**Artikel:** Erfassen kontinuierlicher Bodenbedeckungsdaten anhand von MODIS Daten in der Schweiz  
**Autor:** Schwarz, Markus / Zimmermann, Niklaus E. / Wildi, Otto  
**DOI:** <https://doi.org/10.5169/seals-74726>

### **Nutzungsbedingungen**

Die ETH-Bibliothek ist die Anbieterin der digitalisierten Zeitschriften auf E-Periodica. Sie besitzt keine Urheberrechte an den Zeitschriften und ist nicht verantwortlich für deren Inhalte. Die Rechte liegen in der Regel bei den Herausgebern beziehungsweise den externen Rechteinhabern. Das Veröffentlichen von Bildern in Print- und Online-Publikationen sowie auf Social Media-Kanälen oder Webseiten ist nur mit vorheriger Genehmigung der Rechteinhaber erlaubt. [Mehr erfahren](#)

### **Conditions d'utilisation**

L'ETH Library est le fournisseur des revues numérisées. Elle ne détient aucun droit d'auteur sur les revues et n'est pas responsable de leur contenu. En règle générale, les droits sont détenus par les éditeurs ou les détenteurs de droits externes. La reproduction d'images dans des publications imprimées ou en ligne ainsi que sur des canaux de médias sociaux ou des sites web n'est autorisée qu'avec l'accord préalable des détenteurs des droits. [En savoir plus](#)

### **Terms of use**

The ETH Library is the provider of the digitised journals. It does not own any copyrights to the journals and is not responsible for their content. The rights usually lie with the publishers or the external rights holders. Publishing images in print and online publications, as well as on social media channels or websites, is only permitted with the prior consent of the rights holders. [Find out more](#)

**Download PDF:** 03.05.2026

**ETH-Bibliothek Zürich, E-Periodica, <https://www.e-periodica.ch>**

## Erfassen kontinuierlicher Bodenbedeckungsdaten anhand von MODIS Daten in der Schweiz

Markus Schwarz, Niklaus E. Zimmermann, Otto Wildi und Felix Kienast

Eidg. Forschungsanstalt WSL, Zürcherstrasse 111, CH-8903 Birmensdorf;  
e-mail: markus.schwarz@wsl.ch

Manuskript angenommen am 9. September 2004

### Abstract

Schwarz M., Zimmermann N.E., Wildi O. and Kienast F. 2004. Mapping of land cover continuous fields using MODIS data in Switzerland. Bot. Helv. 114/2: 151–167.

The assessment of large-scale land cover pattern is an important input for monitoring and modeling of ecological and environmental processes. Considerable efforts have recently resulted in the development of global continuous fields for different land cover types at large spatial scales based on NOAA-AVHRR and TERRA-MODIS data. In this study, a new methodology is described for deriving continuous fields of tree cover (coniferous/deciduous) and vegetation not covered by trees as well as non-vegetated land cover for complex topography at the regional scale of Switzerland. The methodology is based upon generalized linear models (GLM). MODIS (MOD09A1) data at a spatial resolution of 500 m was used to calibrate the GLM models. For purpose of validation we compared the resulting continuous fields of tree cover and an available global data set, namely the TERRA-MODIS Vegetation Continuous Fields product (MOD44B) against an independent reference dataset. In comparison with the available global tree continuous field data set (MOD44B), our regional GLM-based tree model obtained significantly better results for all calculated accuracy measures. Tests of the resulting maps showed that non-vegetated, bare ground and vegetation covered by trees were predicted accurately, with weighted Kappa values ( $\kappa_w$ ) reaching 0.87 and 0.85 respectively. Due to the heterogeneous character of “non-tree vegetation” this latter landcover type was predicted with lower precision ( $\kappa_w = 0.79$ ). We conclude that generalized linear models are appropriate for deriving continuous fields of different land cover types for complex topography at a regional scale. Regional calibration of land cover continuous fields offers significantly improved predictions compared to globally calibrated models and may serve as a valuable tool for regional monitoring of land cover pattern and its temporal change.

*Key words:* Change detection, land cover continuous fields, GLM, MODIS, monitoring, remote sensing.

## Einleitung

Der Alpenraum ist immer stärker und sich rascher ändernden Einflüssen ausgesetzt. Nur mit zeitlich hoch aufgelösten, zuverlässigen Informationen über die Verteilung der Bodenbedeckung ist das Ausmass des fortschreitenden Landschaftswandels zu erfassen (Tasser und Tappeiner 2002). Länderübergreifende, konsistente und flächendeckende Informationen der Bodenbedeckung bilden dabei eine wertvolle Basis für die Untersuchung thematischer Aspekte wie Landschaftsveränderung, Energiehaushalt, Wasserhaushalt, Ökosystem-Monitoring, Klimafolgenforschung oder für andere Anwendungen im Bereich von Ressourcenmanagement (Townshend et al. 1994). Verschiedene Untersuchungen von NOAA-AVHRR-Satellitendaten belegen, wie Satellitendaten bereits seit geraumer Zeit für grossflächiges Monitoring Verwendung finden (DeFries und Los 1999; Eidenshink und Faundeen 1994). Ende 1999 wurde mit Terra-EOS ein weiterer Umweltbeobachtungssatellit erfolgreich auf seine Umlaufbahn gebracht. Der sich auf Terra befindende MODIS-Sensor (Moderate Resolution Imaging Spectroradiometer) bietet die Möglichkeit, über grosse Flächen zeitlich hochaufgelöste Bodenbedeckungsinformationen zu beziehen. Dabei wird die gesamte Erdoberfläche innerhalb von 48 Stunden mit 36 verschiedenen Kanälen erfasst. Im Gegensatz zu NOAA-AVHRR mit einer nominellen räumlichen Auflösung von 1100 m, weist MODIS mit 250–1000 m eine bessere räumliche sowie eine wesentlich bessere spektrale Auflösung auf. Die prozessierten und georeferenzierten Reflektanzwerte der einzelnen Kanäle sind unter dem MODIS-Produkt MOD09 erhältlich (Vermote et al. 1997). Anhand von MOD09-Daten wollen wir mit diesem Artikel eine neue Methode vorstellen, welche es erlaubt, die Verbreitung und die zeitliche Veränderung von Baum- und übrigem Grünland, sowie von vegetationsfreien Flächen mit hoher zeitlicher Auflösung zu erfassen und gegebenenfalls zu überwachen.

Ein weit verbreiteter Ansatz zum Erfassen der Bodenbedeckung charakterisiert die Erdoberfläche anhand diskreter Klassen und weist jedem Pixel (=Bildpunkt) einen Bodenbedeckungstypen zu. Solche Karten werden oft als Habitat-, Vegetations- oder Landnutzungskarten bezeichnet. Der englische Begriff *land cover* beschreibt den kartierten Inhalt aber wesentlich besser. In den letzten Jahren wurden grosse Anstrengungen unternommen, um die Generierung von kontinentalen und globalen *land cover* Datensätzen basierend auf Satellitendaten (z.B. NOAA-AVHRR, MODIS, SPOT/VEGETATION) voranzutreiben. Die wichtigsten sind: 1) Global Land Cover 2000 (Latifovic et al. 2004), 2) IGBP global land classification (Townshend et al. 1994; Loveland und Belward 1997), 3) UMD Global land cover classification (Hansen et al. 2000) oder 4) MODIS (MOD12) Global land cover classification (Friedl et al. 2002).

Infolge des kleinräumigen Landschaftsmusters in der Schweiz (bzw. des gesamten Alpenraumes) erweist sich dieser Ansatz für Satellitendaten mit einer räumlichen Auflösung von  $\geq 250\text{m}$  als problematisch und führt zu einem starken Informationsverlust, da innerhalb eines Pixels meist keine reinen Bodenbedeckungstypen vorkommen und das reflektierte Signal somit eine Kombination verschiedener Bodenbedeckungstypen darstellt (= Mischpixel; Aplin und Atkinson 2001). Aus diesem Nachteil ist das Bedürfnis entstanden, Methoden zu entwickeln, anhand derer die heterogene Zusammensetzung eines Pixels beschrieben werden kann. Mit einem derartigen Ansatz wird die Erdoberfläche nicht durch diskrete Klassen, sondern durch kontinuierliche Felder (continuous fields) charakterisiert (Foody 1996). Das bedeutet, dass für jeden Pixel der relative Anteil eines bestimmten Bodenbedeckungstypes bestimmt wird. Kontinuierliche Bodenbedeckungskarten weisen zudem den Vorteil auf, dass sie Landschaftsver-

änderungen rascher und inhaltlich differenzierter erfassen können (Hansen et al. 2002). Die räumliche Auflösung von 250–1000 m dieser Bilddaten wirkt etwas limitierend, doch für ein grossflächiges Landschaftsmonitoring stellt dies kein gravierendes Problem dar.

Die Forschung zur Entwicklung kontinuierlicher Bodenbedeckungskarten mittels Satellitendaten grober Auflösung ist bisher vorwiegend an der Universität von Maryland vorangetrieben worden (Hansen et al. 2002; DeFries et al. 1998; DeFries und Los 1999). So wurden globale Karten basierend auf einem hierarchisch gegliederten statistischen Modell (regression tree kombiniert mit linearen Regressionsmodellen pro terminal node) für ausgewählte Bodenbedeckungstypen (Bäume insgesamt, Laubbäume, Nadelbäume, vegetationsfreie Flächen) erzeugt. Als Datengrundlage werden MODIS-Satellitendaten mit einer räumlichen Auflösung von 500 m verwendet und die resultierenden Karten sind unter dem MODIS-Produkt MOD44B erhältlich (Hansen et al. 2002).

Das Ziel unserer Studie ist es, mittels MODIS-Satellitendaten (MOD09A1) optimierte Karten für 5 wichtige Bodenbedeckungstypen (Baumanteil gesamt, Nadelbäume, Laubbäume, übriges Grünland, vegetationsfreie Flächen) in der kleinräumig gegliederten Landschaft des alpinen Raumes herzustellen. Dazu verwenden wir generalisierte lineare (Regressions-) Modelle (GLM), welche sich für solche Fragestellungen besonders eignen. Wir beschränken uns dabei auf die Schweiz als Testgebiet, welche alle vorhandenen Landschaftstypen im Alpenraum abdeckt. Durch die Kalibrierung mit regionalen Trainingsdaten sollen die generierten Bodenbedeckungskarten auf die Verhältnisse im Alpenraum optimiert und angepasst werden. Dadurch sollen Grundlagen für regionales Monitoring von Landschaftsveränderungen erarbeitet werden. Der GLM-Ansatz stellt eine grundsätzliche Erweiterung der klassischen linearen Regression dar, da ganz unterschiedliche Modell-Familien angewandt werden können. Die binomiale Familie, besser bekannt als Logit-Regression, eignet sich sehr gut für binomial verteilte Zielvariablen (McCullagh und Nelder 1989).

## Material und Methoden

### *Kalibrationsdaten (MODIS-Daten)*

Für die Kalibration der Modelle verwendeten wir Satellitendaten von TERRA-MODIS. Ein besonderes Merkmal von TERRA-MODIS ist, dass die Rohdaten nach automatisierten Verfahren und Algorithmen aufbereitet und dem Endnutzer gratis als georeferenzierte und vollständig prozessierte Bilder zur Verfügung gestellt werden. Nebst den Rohdaten der 36 Kanäle werden über 40 abgeleitete Produkte angeboten (Blattflächenindex, Nettoprimärproduktion, Schneekarten, Oberflächentemperatur, Landcover etc.). Für diese Untersuchung verwendeten wir das MODIS Produkt MOD09A1 (Vermote et al. 1997). Dabei handelt es sich um 8-Tages Komposite der Kanäle 1-7 (sichtbarer bis infraroter Bereich des elektromagnetischen Spektrums) mit einer räumlichen Auflösung von 500 m. Bei der Herstellung dieses Produktes wird pro Pixel der beste Wert aus 8 aufeinander folgenden Tagen ausgewählt. Damit wird sichergestellt, dass die Pixel die geringste atmosphärische Trübung, Bewölkung oder anderweitige Störung aufweisen. Die von uns verwendeten Daten stammen vom Jahr 2001 und wurden auf die geographischen Koordinaten der Schweizerischen Landestopographie umprojiziert und weiterverarbeitet. Um die Datenmenge und qualitätsmindernden Einflüsse zu verringern, wurden analog dem Vorgehen von Holben (1986) die

8-Tages-Komposite zu monatlichen Werten zusammengefasst: In einem ersten Schritt wurde für jedes 8-Tage-Komposit der Normalized Difference Vegetation Index (NDVI) berechnet. In einem zweiten Schritt wurde für jeden Monat nur die spektrale Information des Komposits berücksichtigt, das den höchsten NDVI-Wert aufweist. Analog zu Hansen et al. (2002) verwendeten wir in der Folge nur jene 8 Monatsdaten mit dem höchsten NDVI-Wert. Basierend auf diesen 8 „besten“ Monatswerten wurde ein Datensatz abgeleitet, der für jeden Reflektanzkanal (inklusive NDVI) Mittelwert (Ave), Maximum (Max), Minimum (Min), Spanne (Range) und Standardabweichung (Std) beinhaltet. Dies führt zu einem Datensatz mit 40 ( $8 \times 5$ ) erklärenden Variablen. Wie DeFries et al. (1995, 1998) zeigten, sind diese Parameter geeignet, um den phänologischen Verlauf der Vegetation zu charakterisieren. Die phänologischen Verschiebungen, welche durch Klima und Höhenlage (insbesondere Schnee) verursacht werden, können so minimiert, aber nicht ganz ausgeschlossen werden. Der so aggregierte jährliche Datensatz ist im Vergleich zu monatlichen Parametern weniger sensitiv bezüglich der phänologischen Stadien, der regionalen atmosphärischen Trübungen und der Bewölkung (Hansen et al. 2002). Für die in dieser Studie entwickelten Regressionsanalysen stellt dieser abgeleitete MODIS-Datensatz das Set der erklärenden Variablen dar.

#### *Trainingsdaten*

Die verwendeten Trainingsdaten basieren auf drei unterschiedliche Datenquellen:

- Die Karte des Waldmischungsgrades der Schweiz (WMG25) weist eine räumliche Auflösung von 25 m auf und basiert auf 11 Landsat-5 TM Bildern der Jahre 1990–1992 (Bundesamt für Statistik 2001). Die Satellitenbilder bedecken die ganze Schweiz vollständig und wurden alle im Zeitraum zwischen 14. Juli und 15. September erfasst. Bei TM handelt es sich um einen optischen Sensor, der auf dem Satelliten Landsat-5 installiert ist und die Erdoberfläche mit einer räumlichen Auflösung von etwa 30 m abtastet. Die WMG25-Karte unterscheidet zwischen Wald und Nicht-Wald und gliedert den Wald nach verschiedenen Mischungsstufen, anhand derer der relative Anteil von Nadel- bzw. Laubwald bestimmt werden kann. Diese Daten werden verwendet, um die Abgrenzung der Waldfläche und den Anteil von Nadelbäumen bzw. Laubbäumen zu bestimmen.
- Informationen des 2. Schweizerischen Landesforstinventars (Brassel et al. 1999) wurden verwendet, um für jedes Pixel innerhalb der Waldfläche (basierend auf WMG25-Karte) den effektiven Baumdeckungsgrad zu bestimmen. Anhand einer multiplen linearen Regression wird der Baumdeckungsgrad (Zielvariable) durch topographische und bioklimatische Variablen (erklärende Variable) modelliert. Mittels dieser statistischen Regression lassen sich die Wald-Pixel aus dem ersten Datensatz in relative Baumdeckungsgrade umwandeln.
- Die Arealstatistik gibt Auskunft über die Verteilung der Bodennutzung und -bedeckung in den Bereichen Wald, Siedlung, Gras- und Kulturland sowie unproduktive Flächen (Jordi 2001). Gesamthaft werden 69 Kategorien unterschieden. Es handelt sich dabei um einen stichprobenbasierten Datensatz, dem ein regelmässiges Netz von  $100 \text{ m} \times 100 \text{ m}$  zugrunde liegt. Die Interpretation erfolgt auf Luftbildern (Aufnahmedatum: 1992–1997) und weist jedem Stichprobenpunkt eine der 69 Kategorien des Nutzungskataloges zu, welche für den ganzen Bildpunkt gilt. Ähnlich wie DeFries et al. (1998) weisen wir den verschiedenen Nutzungskategorien ausserhalb des Waldes einen mittleren Deckungsgrad (für jeden Bodenbedeckungstyp) zu. Für die Baumbedeckung ausserhalb der Waldfläche wurden beispielsweise folgende Regeln aufgestellt: Hecken und Baumgruppen wurde ein Deckungsgrad von 40% zugewiesen, Obstbauflächen ein

Deckungsgrad von 30%, Gebäudeumschwung ein Deckungsgrad von 15% und Erholungs- und Grünanlagen ein Deckungsgrad von 20%.

Der Trainingsdatensatz für die Baumbedeckung bzw. Nadel- und Laubbaumanteile basiert auf einer Kombination der drei Datenquellen: Innerhalb der Waldfläche wurde der berechnete Baumdeckungsgrad verwendet und ausserhalb der Waldfläche wurden die festgelegten Deckungsgrade basierend auf der Arealstatistik verwendet. Die Trainingsdatensätze für „übriges Grünland“ und „vegetationsfreie Flächen“ basieren ausschliesslich auf den festgelegten Deckungsgraden der einzelnen Nutzungskategorien der Arealstatistik. Die Daten wurden in einem nächsten Schritt auf die räumliche Auflösung von MODIS skaliert, wobei für jeden Bodenbedeckungstyp der relative Anteil innerhalb eines 500 m-MODIS-Pixels berechnet wurde. Dies führt zu 5 Datensätzen (für jeden Bodenbedeckungstyp einen), welche je 165'622 Datenpunkte und eine räumliche Auflösung von 500 m aufweisen. Als Trainingsgebiet für die Modellkalibration dient der östliche Teil der Schweiz (Abb. 1), wobei gesamthaft nur 7% der Pixel innerhalb des Trainingsgebietes verwendet werden. Anhand der für das Modell nicht verwendeten Pixel kann die Modellkalibration innerhalb des Trainingsgebietes evaluiert werden. Zusätzlich wird die Modellqualität ausserhalb des Trainingsgebietes in einem räumlich unabhängigen Testgebiet (westlicher Teil der Schweiz, Abb. 1) getestet.

Die Genauigkeit der Trainingsdaten wird einerseits durch den unterschiedlichen Datenerhebungszeitpunkt (Trainingsdaten verglichen mit Kalibrationsdaten) und andererseits durch die verwendete Methodik der Datenerhebung beeinflusst. Aufgrund der eher restriktiven Gesetzgebung in der Schweiz geschieht die Land-Umnutzung vor allem im Bereich Wald-Nicht-Wald eher langsam. Die durch die zeitliche Verschiebung zwischen Trainings- und Kalibrationsdaten erzeugten Inkonsistenzen wirken sich daher nicht stark auf die Modellqualität aus. Dies zeigt sich in den erzielten Korrelationskoeffizienten zwischen Trainings- und Kalibrationsdaten. Eine exakte Abschätzung des Fehlers ist aber anhand der vorhandenen Daten nicht möglich. Die Verwendung von modernern Trainingsdaten würde die Modellgenauigkeit allerdings erhöhen.

#### *Vergleichsdaten (MOD44B)*

Unter der MODIS-Produktebezeichnung MOD44B (Hansen et al. 2002) sind globale Karten erhältlich, welche die kontinuierliche Verteilung unterschiedlicher Bodenbedeckungstypen abbilden. Zum Zeitpunkt der Studie (2003) war nur ein Datensatz für Baumbedeckung erhältlich. Dieser globale Datensatz wird mit dem in der Schweiz optimierten GLM-Modell verglichen. Damit soll abgeschätzt werden, inwiefern die Qualität unseres Modells für die Baumbedeckung durch eine Optimierung auf regionale Verhältnisse verbessert werden kann. Die Algorithmen für die Berechnung der globalen Karten wurden im Auftrag der NASA von der Universität von Maryland entwickelt. Um die relativen Anteile eines bestimmten Bodenbedeckungstypes zu schätzen, wurden Regressions-Bäume (regression tree) in Kombination mit linearer Regression (pro terminalem Knoten) angewandt. Die räumliche Auflösung beträgt ebenfalls 500 m.

#### *Unabhängiger Referenzdatensatz*

Zusätzlich zum Test in einem unabhängigen Gebiet wird die Genauigkeit des globalen MODIS-MOD44B Datensatzes und unseres GLM-basierten Modells für Baumbe-




Abb. 1. Überblick über das Untersuchungsgebiet. 7% der 500 m Rasterdaten im Trainingsgebiet wurden verwendet, um das Modell zu kalibrieren. Die übrigen Daten wurden für die Validierung innerhalb des Kalibrationsgebietes, sowie in einem neuen Testgebiet verwendet. Das nördlich gelegene Referenzgebiet stellt eine Testregion dar, wo mit neuen, unabhängigen, TM-basierten Daten getestet wurde.

deckung mit einem unabhängigen Referenzdatensatz verglichen und validiert. Für die Herstellung dieses Datensatzes verwendeten wir ein Landsat-7 TM Satellitenbild vom 15.08.2001 (räumliche Ausdehnung vgl. Abb. 1); es wurde somit im selben Jahr wie die MODIS-Kalibrationsdaten aufgenommen. Zahlreiche Untersuchungen in der Schweiz haben in der Vergangenheit gezeigt, dass mit TM-Daten eine zuverlässige Waldklassifikation möglich ist (Bundesamt für Statistik 2001; Kellenberger 1996). Die erzielten Genauigkeiten liegen bei 90-92%. Das TM-Bild wurde analog dem Vorgehen in dieser Studie bearbeitet. Als Trainingsdaten dienten punktgenaue, luftbildbasierte Auswertungen, welche im Rahmen des Schweizerischen Landesforstinventars für die ganze Schweiz erhoben werden (Brändli und Brassel 2001). Die 7 Kanäle des Landsatbildes wurden als erklärende Variable verwendet. Damit wurde ein GLM-Modell kalibriert ( $D^2 = 0.85$ ), welches anschliessend auf das ganze Bild angewendet wurde, womit ein flächendeckender Datensatz für die prozentuale Baumbedeckung hergestellt werden konnte. Auch dieser Datensatz wurde anschliessend auf die räumliche Auflösung eines MODIS-Pixels skaliert, um den relativen Anteil der Baumbedeckung pro 500 m-Pixel zu bestimmen.

#### *Statistische Modellentwicklung*

Mit einem statistischen Modell wird die Beziehung einer Zielvariablen (hier Deckungsgrad einzelner Bodenbedeckungstypen) von einem Set erklärender Varia-

blen (hier abgeleitet statistische Werte der MODIS Reflektanzkanäle) hergeleitet. Im Falle von kontinuierlichen Bodenbedeckungsdaten wurde dies bisher anhand von Regressionsbäumen (DeFries et al. 1997), von „Linear Mixture Models“ (Adams et al. 1995), oder von neuronalen Netzen (Atkinson et al. 1997) kalibriert. Grundsätzlich lassen sich solche Probleme auch mit klassischer multipler Regression lösen. Die multiple Regression stellt allerdings restriktive Bedingungen an die Zielvariable und an die Verteilung der Residuen. So müssen die Residuen normalverteilt sein, und die Zielvariable sollte nicht durch eine untere und obere Begrenzung des Gültigkeitsbereiches limitiert sein. Solche Fälle können mittels Generalisierten Linearen Modellen (GLM) gelöst werden, welche eine Erweiterung des so genannten „linearen Modells“ (klassische Regression) darstellen (Dobson 2002; Green und Silverman 1994; McCullagh und Nelder 1989). GLMs erlauben dabei eine breitere Anwendung und unterstützen zahlreiche zusätzliche Verteilungsfamilien (Binomial, Poisson etc.). Eine Übersicht über GLM und ähnliche Modelle sowie deren Verwendung in der Ökologie ist in Guisan und Zimmermann (2000) zusammengefasst.

Für jeden der 5 Bodenbedeckungstypen wurde ein separates Modell entwickelt, wobei wir jeweils den binomialen Verteilungstyp verwendeten (auch bekannt als Logit Regression). Die unter „Trainingsdaten“ aufgearbeiteten und konvertierten Daten wurden als Zielvariable verwendet. Als erklärende Variablen wurden die unter „Kalibrationsdaten (MODIS-Daten)“ beschriebenen und weiterverarbeiteten MODIS-Daten verwendet. Ausgehend von einem maximalen Modell (40 Variablen), welches alle möglichen Variablen in linearer und quadratischer Form umfasst, wurden die Modelle schrittweise statistisch optimiert, wobei mittels der „backward“ und „forward“ Methode (Guisan und Zimmermann 2000) die nicht-signifikanten Variablen eliminiert wurden. Für die Kalibrierung der Modelle wurde von den 165'622 Bildpunkten des Trainingsdatensatzes nur 11'387 verwendet ( $\approx 7\%$ ), welche sich ausschliesslich auf das Trainingsgebiet beziehen (Abb. 1). Die Qualität der Modellkalibration wird bei GLMs mittels des  $D^2$  ausgewiesen, analog zum  $R^2$  bei der linearen Regression.

#### *Validierung und Vergleich*

Um die Qualität des Modells zu testen, wurden die simulierten Karten für die 5 Bodenbedeckungstypen einerseits mit den für die Kalibration nicht verwendeten Punkten innerhalb des Trainingsgebietes und andererseits mit den Punkten ausserhalb des Trainingsgebietes verglichen (Testgebiet; Abb. 1). Zusätzlich wurde der simulierte Baumdeckungsgrad sowohl für das GLM-Modell wie auch für den globalen MODIS-VCF Datensatz mit einem unabhängigen Referenzdatensatz (siehe „Unabhängiger Referenzdatensatz“) verglichen.

Für die Abschätzung der Genauigkeiten wurden verschiedene statistische Masse verwendet: 1) der Mittelwert der absoluten Fehlerrate (MAE), 2) die korrekte Klassifikationsrate ( $CCR_0$  bzw.  $CCR_i$ ; Fielding 1999), 3) Kappa ( $\kappa$ ) wie auch gewichtetes Kappa ( $\kappa_w$ ) sowie 4) der quadrierte Korrelationskoeffizient (Pearson  $R^2$ ). Für die Berechnung der Masse 2 und 3 werden die simulierten Daten mittels einer Kreuztabelle den beobachteten Testdaten in 20% Bedeckungsklassen gegenüber gestellt. Die Bedeckung ist dann perfekt simuliert, wenn alle simulierten Werte in dieselbe (20%)-Klasse fallen wie die beobachteten Werte. Der Wert  $CCR_0$  beschreibt den Anteil der korrekt simulierten Klassen.

Der von Cohen (1960) eingeführte Kappa-Koeffizient ( $\kappa$ ) ist ein verbreitetes Mass, um auf ähnliche Weise die Übereinstimmung zweier Datensätze zu bestimmen; er wird oft für Kartenvergleiche verwendet (Monserud und Leemans 1992). Dabei wird die

Übereinstimmung zweier Datensätze anhand einer Kontingenztabelle mit der Zufallsübereinstimmung verglichen, wie sie anhand der a priori Wahrscheinlichkeiten der Klassen zu erwarten wären. Der höchstmögliche Wert für  $\kappa$  ist gleich 1, er bedeutet perfekte Übereinstimmung. Ein  $\kappa$  von 0 ist gleichbedeutend mit zufälliger Übereinstimmung der Datensätze, während negative Werte systematische Fehler anzeigen.

$$\kappa = \frac{P_o - P_e}{1 - P_e} \quad (1)$$

wobei

$$P_o = \sum_{i=1}^r p_{ii} \quad (2) \quad \text{und} \quad P_e = \sum_{i=1}^r p_{i.} \times p_{.i} \quad (3)$$

$p_{ii}$  steht für die Pixelzahl, welche in beiden Karten für die Klasse  $i$  übereinstimmt.  $p_{i.}$  steht für den Anteil Pixel der Klasse  $i$  in der geschätzten oder simulierten Karte und  $p_{.i}$  steht für den Anteil Pixel der Klasse  $i$  in der Referenzkarte. Das Produkt  $p_{i.} \times p_{.i}$  ist die erwartete Zufallsübereinstimmung zweier Karten für die Klasse  $i$ . Der gewichtete Kappa-Koeffizient ( $\kappa_w$ ) ist ein von  $\kappa$  abgeleitetes Mass und wurde von Cohen (1968) und Fleiss et al. (1969) entwickelt. Er kann verwendet werden, um eine Gewichtung der auftretenden Fehler vorzunehmen. Das Gewicht ( $w_{ij}$ ) quantifiziert den Grad der Ähnlichkeit zweier Klassen, indem Fehler beim Verwechseln von Klassen mit grosser Ähnlichkeit weniger stark gewichtet werden als Fehler zwischen stark unähnlichen Klassen.

$$\kappa_w = \frac{P_{o(w)} - P_{e(w)}}{1 - P_{e(w)}} \quad (4)$$

wobei

$$P_{o(w)} = \sum_i \sum_j w_{ij} p_{ij} \quad (5) \quad \text{und} \quad P_{e(w)} = \sum_i \sum_j w_{ij} p_{i.} p_{.j} \quad (6)$$

Die Gewichtung  $w_{ij}$  wird entsprechend der gleichmässig verteilten und absoluten Differenz zweier Klassen berechnet.  $w_{ij}$  quantifiziert den Grad des Fehlers zwischen zwei Klassen  $i$  und  $j$ . Bildpunkte, die auf der Diagonalen einer Kontingenztabelle zu liegen kommen, weisen ein  $w_{ij}$  von 1 auf; wobei Bildpunkte mit grossem Unterschied von  $i$  und  $j$  eine Gewichtung nahe 0 erhalten. Dieses Mass eignet sich speziell für das Testen von Klassen mit abgestufter Ähnlichkeit, da es eine Gewichtung der Fehler zulässt (Cicchetti und Allison 1971).

$$w_{ij} = 1 - \frac{|i - j|}{|r - 1|} \quad (7)$$

In unserer Untersuchung verwenden wir das gewichtete Kappa ( $\kappa_w$ ), da geringe Abweichungen der modellierten von den beobachteten Deckungswerten weniger stark gewichtet werden sollen als starke Abweichungen. Das Gewicht ergibt sich aus der Differenz.

Tab. 1. Kalibrierte GLM-Modelle für die fünf untersuchten Bodenbedeckungstypen. Die Modellqualität bezeichnet, wie gut die Kalibration ist. Die Modellgenauigkeiten sind berechnete Genauigkeitsmasse anhand unabhängiger Daten 1) innerhalb des Trainingsgebietes (anhand von Pixeln, welche für die Kalibration nicht verwendet wurden), und 2) in einem neuen Testgebiet (ausserhalb des Trainingsgebietes).

	vegetationsfreie Flächen		übriges Grünland		Baumbedeckung		Nadelbaum		Laubbaum	
Modellqualität										
$D^2$	0.73		0.51		0.73		0.65		0.67	
Modell- genauigkeit	Training	Test	Training	Test	Training	Test	Training	Test	Training	Test
$\kappa_w$	0.87	0.88	0.79	0.77	0.85	0.85	0.83	0.85	0.85	0.85
CCR <sub>0</sub>	0.76	0.82	0.37	0.31	0.57	0.59	0.60	0.67	0.80	0.80
MAE	0.10	0.08	0.16	0.17	0.09	0.10	0.09	0.09	0.05	0.06

## Resultate

Für alle fünf Bodenbedeckungstypen lässt sich ein gültiges Modell kalibrieren mit den in Tabelle 1 angegebenen Modellqualitäten und -genauigkeiten. Mit Ausnahme des übrigen Grünlandes ( $D^2 = 0.51$ ) liefern die Modelle eine ähnlich hohe Modellqualität. Die  $D^2$ -Werte weichen nicht stark voneinander ab und variieren zwischen 0.65 und 0.73. Die Modellgenauigkeiten sind jeweils getrennt nach Trainingsgebiet (Ost) und Testgebiet (West) angegeben (Abb. 1) und zeigen ein ähnliches Bild wie die Modellqualitäten: Die erzielten Genauigkeiten für den Bodenbedeckungstyp „übriges Grünland“ sind deutlich schlechter im Vergleich zu den anderen Bodenbedeckungstypen. Ausserdem sind keine signifikanten Unterschiede zwischen Trainingsgebiet und Testgebiet festzustellen. In Abbildung 2 sind die aus dem Modell berechneten Deckungsanteile der jeweiligen Bodenbedeckungstypen gegen die beobachteten Deckungsanteile der Referenzpixel in einem Diagramm dargestellt. Um die einzelnen Graphiken übersichtlicher zu gestalten, sind nur 10% der verwendeten Trainingspixel, welche zufällig ausgewählt wurden, dargestellt. Für das Modell GLM-Baumbedeckung wurde ein  $R^2$  von 0.72 erzielt, die entsprechenden  $R^2$ -Werte für die Nadel- und Laubbaum Modelle betragen 0.61 bzw. 0.64. Am besten kalibriert wurde das Modell „vegetationsfrei“ ( $R^2 = 0.77$ ), während das Modell „übriges Grünland“ am schlechtesten abschnitt ( $R^2 = 0.54$ ).

Die simulierten Karten der Schweiz für die Baumbedeckung, für „übriges Grünland“ und für „vegetationsfreie Flächen“ sind in den Abbildungen 3a–c dargestellt. Die Abbildung 4 stellt eine Kombination dieser drei Karten in Form eines RGB-Farbkomposits dar. Der Rotkanal entspricht dem Anteil „vegetationsfreier Flächen“, der Blaukanal entspricht der Baumbedeckung“ und der grüne Kanal repräsentiert den Anteil „übriges Grünland“ pro Pixel. Entsprechend dieser Farbzuordnung erscheinen von Bäumen dominierte Flächen blau, vorwiegend vegetationsfreie Flächen erscheinen rot und von „übrigem Grünland“ dominierte Flächen sind grün eingefärbt.

In Tabelle 2 sind die berechneten Genauigkeiten der Validierung des GLM-Modells Baumbedeckung und dem globalen MODIS-VCF Datensatz mit dem unab-




Abb. 2. Zusammenhang zwischen simulierten und effektiven Anteilen der untersuchten Bodenbedeckungstypen. Der Grad der Korrelation ist durch den quadrierten Korrelationskoeffizienten ( $R^2$ ) angegeben. Die 1:1 Linie ist zur erleichterten Analyse der Grafiken eingefügt.

hängigen, TM-basierten Referenzdatensatz zusammengestellt. Mit dem GLM-Modell wird die totale von Bäumen bedeckte Fläche um 6.5% unterschätzt. Gesamthaft werden 50% aller Pixel in der richtigen 20%-Klasse simuliert und der mittlere absolute Fehler (MAE) beträgt 0.13. Der Wert des gewichteten Kappa's ( $\kappa_w$ ) beträgt 0.83 (Tab. 2). Der Datensatz MODIS-VCF überschätzt die aufsummierte von Bäumen bedeckte Fläche um +25% und weist einen  $CCR_0$  Wert von 0.40 auf. Der MAE beträgt 0.23 und  $\kappa_w$  erreicht 0.40 (Tab. 2).

## Diskussion

Die erzielten Genauigkeiten (Tab. 1) zeigen, dass sich MOD09A1-Daten und GLM-Modelle gut für die Kalibration des relativen Deckungsgrades der untersuchten Bodenbedeckungstypen eignen. Das beste Modell wurde für „vegetationsfreie Flächen“ erzielt. Dies ist vor allem auf die ausgedehnten hochalpinen Flächen zurückzuführen, in welchen die dominierenden Bodenbedeckungen Schnee, Eis und Fels mit hoher Zuverlässigkeit erkannt werden. Wie Abbildung 4 zeigt, werden aber auch die urbanen Ballungszentren gut wiedergegeben. Die Deckungsanteile von Bäumen werden ebenfalls gut erkannt. Probleme treten vor allem in steilen Hanglagen auf. An nördlich exponierten Hängen tendiert das Modell zu einer Überschätzung des Baumanteiles, im Gegensatz zu südlich exponierten Hängen. Beides kann auf den Sonnen-




Abb. 3a. MODIS-basierte Verteilung der Baumbedeckung in der Schweiz.




Abb. 3b. MODIS-basierte Anteile des „übrigen Grünlandes“ in der Schweiz.




Abb. 3c. MODIS-basierte Anteile der „vegetationsfreien Flächen“ in der Schweiz.




Abb. 4. Farbkomposit der Modelle für Baumbedeckung, vegetationsfreie Flächen und übriges Grünland. Der Rotkanal entspricht der Karte für vegetationsfreie Flächen, der Grünkanal derjenigen für das übrige Grünland und der blaue Kanal wird durch den Baumdeckungsgrad wiedergegeben.

einfallswinkel zurückgeführt werden, welcher für Beschattung (Nordhänge) und Überstrahlung (Südänge) verantwortlich ist. Durch Einbezug von topographischen Zusatzinformationen, welche von einem digitalen Höhenmodell (DHM) abgeleitet werden, könnten diese Effekte zum Teil korrigiert werden. Die hohen Korrelationskoeffizienten für Nadel- und Laubbaum (0.61 bzw. 0.64) deuten darauf hin, dass Nadelbäume und Laubbäume gut voneinander unterschieden werden können. Dies ist auch daraus ersichtlich, dass die Summe der Deckungsanteile von Nadel- und Laubbäumen fast identisch ist mit den simulierten Baum-Anteilen. Mit einem  $R^2$  von 0.54 wird „übriges Grünland“ am wenigsten gut simuliert. Dies ist auf den sehr heterogenen Charakter dieses Bodenbedeckungstyps zurückzuführen. Neben landwirtschaftlichen Flächen, die ihr Erscheinungsbild im Laufe eines Jahres sehr stark ändern, umfasst dieser Bodenbedeckungstyp auch alle Trocken-, Fett- und Magerwiesen sowie urbane Grünflächen, verbuschte Wiesen und Weiden sowie andere kraut- und grasdominierte Nichtwaldflächen. Dieser heterogene Charakter erschwert eine eindeutige Klassifikation. Eine feinere Unterscheidung in mehrere Klassen könnte das Erfassen mittels GLM-Modellen wesentlich verbessern, verlangt aber entsprechende Kalibrationsdaten. Trotz diesen Problemen liefert die resultierende Verteilungskarte einen guten Überblick, aus der auch der Grünlandanteil in urbanen Gebieten wie Parkanlagen, Vorgärten etc. gut ersichtlich wird.

Tab. 2. Validierung des GLM-Modells für Baumbedeckung und des globalen MODIS-VCF Datensatzes mit einem unabhängigen, TM-basierten Referenzdatensatz.

	GLM-Baumbedeckung	MODIS-VCF
Total Fläche [km <sup>2</sup> ]	13640	13640
Von Bäumen bedeckte Fläche Referenz [km <sup>2</sup> ]	5139	5139
Von Bäumen bedeckte Fläche simuliert [km <sup>2</sup> ]	4805	6406
Mittlerer Fehler (Bias)	-6.5%	+24.7%
Mittlerer Absolutfehler (MAE)	0.13	0.22
CCR <sub>0</sub>	0.50	0.40
$\kappa_w$	0.82	0.73

Die Validierung der Baumbedeckung des GLM-Modells und des MODIS-VCF Datensatzes zeigt, dass die regional kalibrierte Waldkarte eine deutlich höhere Genauigkeit aufweist. Alle berechneten Genauigkeitsmassen sind zum Teil deutlich höher als diejenigen des MODIS-VCF Datensatzes. In Abbildung 5 ist der mittlere Fehler (Bias) in Abhängigkeit des Baumdeckungsgrades dargestellt. Positive Abweichungen deuten auf eine Überschätzung, negative Abweichungen auf eine Unterschätzung des simulierten Deckungsgrades hin. Es wird deutlich, dass der Baumdeckungsgrad mit dem MODIS-VCF Datensatz generell überschätzt wird, wobei der Bias bis zu einem relativen Baumdeckungsgrad von 75% positiv (= Überschätzung des Waldanteiles) ist. Laticovic und Olthof (2004) errechneten in ihrer Validierung von globalen Landbedeckungskarten Gesamtgenauigkeiten zwischen 0.27–0.45. Die von uns erzielte Gesamtgenauigkeit für die Baumbedeckung liegt mit 0.5 leicht über diesen Werten. Dies zeigt, dass der GLM-Datensatz mindestens eine vergleichbare Qualität aufweist, obwohl anzumerken bleibt, dass ein Vergleich mit diskreten Landbedeckungskarten nur bedingt sinnvoll ist, da sich die angewandte Methodik stark unterscheidet.

### Schlussfolgerungen

Wie bereits mehrere Untersuchungen zu diesem Thema gezeigt haben (DeFries et al. 1998; Foody und Cox 1994; Hansen et al. 2002), bieten kontinuierliche bodenbedeckungsspezifische Erfassungstechniken eine wertvolle Alternative zu herkömmlichen diskreten Klassifikationen. Kontinuierliche Bodenbedeckungsdaten bieten eine höhere Informationsdichte bei gleicher räumlicher Auflösung und eine höhere Flexibilität, um Landschaftsveränderungen im Sub-Pixel Bereich relativ rasch zu erfassen. Wegen der hohen zeitlichen Auflösung können mittels MODIS Daten bereits nach wenigen Monaten neue Modelle kalibriert werden.

Die simulierten Karten weisen im Allgemeinen eine hohe Korrelation mit den Trainingsdaten auf. Die Modellgenauigkeiten unterscheiden sich dabei nicht signifikant, wenn man innerhalb des Trainingsgebietes oder ausserhalb des Trainingsgebietes (Testgebiet) in einem räumlich getrennten Gebiet testet. Dies bedeutet, dass die angewendete Methode robust ist und mit Vorsicht auf das erweiterte Alpengebiet angewendet werden kann. Wir sind allerdings der Meinung, dass eine Verbesserung der Resultate erzielt werden kann, indem der Bodenbedeckungstyp „übriges Grünland“

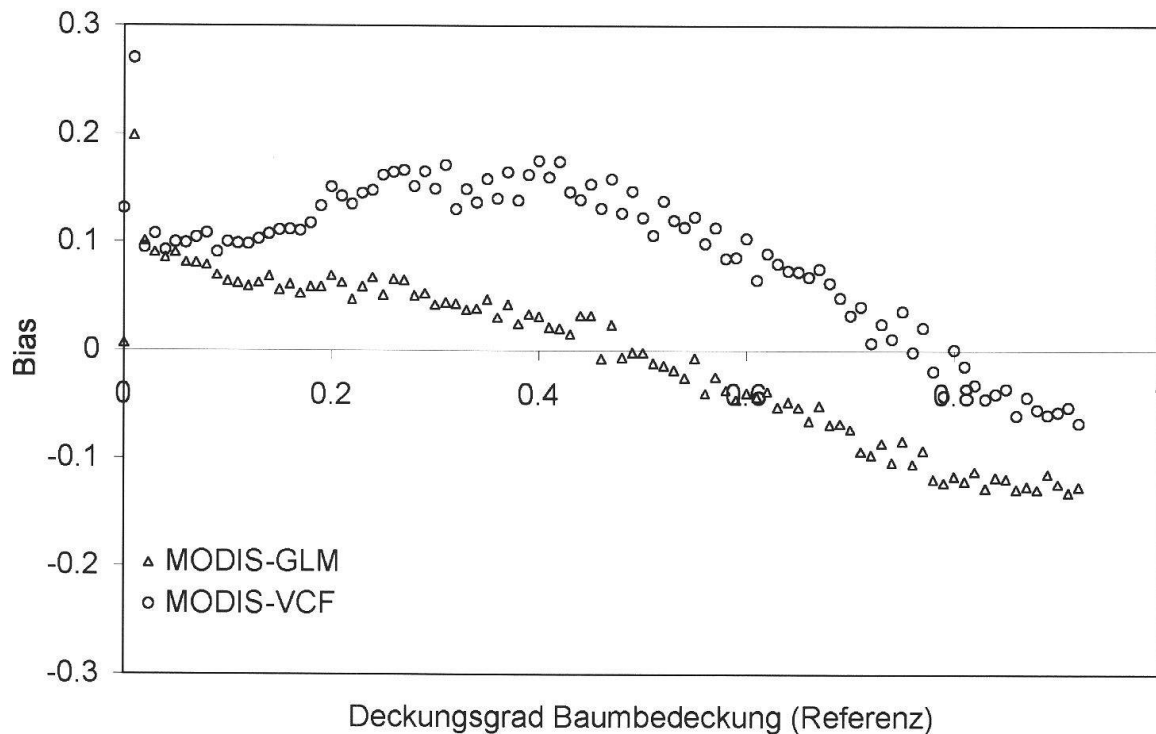


Abb.5. Mittlere Abweichung für das Modell für Baumbedeckung und für den globalen MODIS-VCF Datensatz in Abhängigkeit des Bedeckungsgrades. Die für die Modellkalibration verwendeten Punkte wurden von der Analyse ausgeschlossen.

feiner differenziert wird (z.B. Magerwiesen, Fettwiesen, verbuschtes Grünland, Moore etc.). Hierzu ist allerdings der verwendete Trainingsdatensatz ungenügend.

Die hergestellten Daten liefern eine wertvolle Basis für das Überwachen von Landschaftsveränderungen im regionalen Kontext der Schweiz (oder des Alpenraumes).

Die vorgestellte Methode basiert auf einer hohen zeitlichen Auflösung, der für die Kalibration verwendeten Daten, wobei Komposit-Bilder (7 Kanäle) im 8-Tagesrhythmus verwendet wurden. Für die verwendete räumliche Auflösung von 500 m sind keine zusätzlichen spektralen Informationen erhältlich. Erst in einer Auflösung von 1 km sind weitere 29 Kanäle erhältlich. Es ist denkbar und bleibt zu untersuchen, ob die Modellqualität mit dieser zusätzlichen Information verbessert werden könnte.

Wie der Vergleich mit dem globalen MODIS-VCF Datensatz zeigt, sind unsere Resultate für die Baumbedeckung deutlich besser. Dies bedeutet einerseits, dass sich die statistische Regression mittels GLM gut für die Kalibration der kontinuierlichen Deckungsanteile eignet. Andererseits wird deutlich, dass sich durch die regionale Anpassung des Modells auf den alpinen Raum deutlich bessere Resultate erzielen lassen.

## Literatur

- Adams J.B., Sabol D.E., Kapos V., Almeida R., Roberts D.A., Smith M.O. and Gillespie A.R. 1995. Classification of Multispectral Images Based on Fractions of Endmembers – Application to Land-Cover Change in the Brazilian Amazon. *Rem. Sens. Environ.* 52(2): 137–154.

- Aplin P. and Atkinson P.M. 2001. Sub-pixel land cover mapping for per-field classification. *Intern. J. Rem. Sens.* 22(14): 2853–2858.
- Atkinson P.M., Cutler M.E.J. and Lewis H. 1997. Mapping sub-pixel proportional land cover with AVHRR imagery. *Intern. J. Rem. Sens.* 18(4): 917–935.
- Brändli U.-B. and Brassel P. 2001. Swiss national forest inventory methods and models of the second assessment. WSL, Birmensdorf, 336 pp.
- Brassel P., Brändli U.-B., Eidgenössische Forschungsanstalt für Wald Schnee und Landschaft (Birmensdorf) und Bundesamt für Umwelt Wald und Landschaft 1999. Schweizerisches Landesforstinventar: Ergebnisse der Zweitaufnahme 1993–1995. Haupt, Bern, Stuttgart, Wien, 442 pp.
- Bundesamt für Statistik 2001. GEOSTAT Benutzerhandbuch. Bundesamt für Statistik, Switzerland, Neuenburg, 458 pp.
- Cicchetti D. and Allison T. 1971. A new Procedure for Assessing Reliability of Scoring EEG Sleep Recordings. *Am. J. EEG Technol.* 41: 101–109.
- Cohen J. 1960. A coefficient of agreement for nominal scales. *Educ. Psychol. Meas.* 20(1): 37–46.
- Cohen J. 1968. Weighted Kappa: nominal scale agreement with provision for scaled disagreement or partial credit. *Psychol. Bull.* 70: 213–220.
- DeFries R., Hansen M., Steininger M., Dubayah R., Sohlberg R. and Townshend J. 1997. Subpixel forest cover in central Africa from multisensor, multitemporal data. *Rem. Sens. Environ.* 60(3): 228–246.
- DeFries R., Hansen M. and Townshend J. 1995. Global discrimination of land cover types from metrics derived from AVHRR pathfinder data. *Rem. Sens. Environ.* 54(3): 209–222.
- DeFries R.S., Hansen M., Townshend J.R.G. and Sohlberg R. 1998. Global land cover classifications at 8 km spatial resolution: the use of training data derived from Landsat imagery in decision tree classifiers. *Intern. J. Rem. Sens.* 19(16): 3141–3168.
- DeFries R.S. and Los S.O. 1999. Implications of land-cover misclassification for parameter estimates in global land-surface models: An example from the simple biosphere model (SiB2). *Photogramm. Engin. Rem. Sens.* 65(9): 1083–1088.
- Dobson A.J. 2002. An introduction to generalized linear models. Chapman & Hall/CRC, Boca Raton, 225 pp.
- Eidenshink J.C. and Faundeen J.L. 1994. The 1 km AVHRR Global Land Data Set – 1st Stages in Implementation. *Intern. J. Rem. Sens.* 15(17): 3443–3462.
- Fielding A.H. 1999. Machine learning methods for ecological applications. Kluwer, Boston, 261 pp.
- Fleiss J.L., Cohen J. and Everitt B.S. 1969. Large Sample Standard Errors of Kappa and Weighted Kappa. *Psychol. Bull.* 72(5): 323–332.
- Foody G.M. 1996. Relating the land-cover composition of mixed pixels to artificial neural network classification output. *Photogramm. Engin. Rem. Sens.* 62(5): 491–499.
- Foody G.M. and Cox D.P. 1994. Sub-Pixel Land-Cover Composition Estimation using a Linear Mixture Model and Fuzzy Membership Functions. *Intern. J. Rem. Sens.* 15(3): 619–631.
- Friedl M.A., McIver D.K., Hodges J.C.F., Zhang X.Y., Muchoney D., Strahler A.H., Woodcock C.E., Gopal S., Schneider A., Cooper A., Baccini A., Gao F. and Schaaf C. 2002. Global land cover mapping from MODIS: algorithms and early results. *Rem. Sens. Environ.* 83(1–2): 287–302.
- Green P.J. and Silverman B.W. 1994. Nonparametric regression and generalized linear models a roughness penalty approach. Chapman & Hall / CRC, London, 182 pp.
- Guisan A. and Zimmermann N.E. 2000. Predictive habitat distribution models in ecology. *Ecol. Model.* 135(2–3): 147–186.
- Hansen M.C., Defries R.S., Townshend J.R.G. and Sohlberg R. 2000. Global land cover classification at 1km spatial resolution using a classification tree approach. *Intern. J. Rem. Sens.* 21(6–7): 1331–1364.
- Hansen M.C., DeFries R.S., Townshend J.R.G., Sohlberg R., Dimiceli C. and Carroll M. 2002. Towards an operational MODIS continuous field of percent tree cover algorithm: examples using AVHRR and MODIS data. *Rem. Sens. Environ.* 83(1–2): 303–319.

- Holben B.N. 1986. Characteristics of Maximum-Value Composite Images from Temporal AVHRR Data. *Intern. J. Rem. Sens.* 7(11): 1417–1434.
- Jordi B. 2001. Bodennutzung im Wandel Arealstatistik Schweiz. Bundesamt für Statistik, Neuchâtel, 31 pp.
- Kellenberger T.W. 1996. Erfassung der Waldfläche in der Schweiz mit multispektralen Satellitenbilddaten: Grundlagen, Methodenentwicklung und Anwendung. Department of Geography Remote Sensing Laboratories, University of Zürich-Irchel, Zürich, 284 pp.
- Latifovic R. and Olthof I. 2004. Accuracy assessment using sub-pixel fractional error matrices of global land cover products derived from satellite data. *Rem. Sens. Environ.* 90(2): 153–165.
- Latifovic R., Zhu Z.L., Cihlar J., Giri C. and Olthof I. 2004. Land cover mapping of north and central America – Global Land Cover 2000. *Rem. Sens. Environ.* 89(1): 116–127.
- Loveland T.R. and Belward A.S. 1997. The IGBP-DIS global 1 km land cover data set, DISCover: first results. *Intern. J. Rem. Sens.* 18(15): 3291–3295.
- McCullagh P. and Nelder J.A. 1989. Generalized linear models. Chapman and Hall, London, 511 pp.
- Monserud R.A. and Leemans R. 1992. Comparing global vegetation maps with the Kappa statistic. *Ecol. Model.* 62(4): 275–293.
- Tasser E. and Tappeiner U. 2002. Impact of land use changes on mountain vegetation. *Appl. Veget. Sci.* 5(2): 173–184.
- Townshend J.R.G., Justice C.O., Skole D., Malingreau J.P., Cihlar J., Teillet P., Sadowski F. and Ruttanberg S. 1994. The 1 km Resolution Global Data Set – Needs of the International Geosphere Biosphere Program. *Intern. J. Rem. Sens.* 15(17): 3417–3441.
- Vermote E.F., El Saleous N., Justice C.O., Kaufman Y.J., Privette J.L., Remer L., Roger J.C. and Tanre D. 1997. Atmospheric correction of visible to middle-infrared EOS-MODIS data over land surfaces: Background, operational algorithm and validation. *J. Geophys. Res.-Atmosph.* 102(D14): 17131–17141.

**Anhang**

Modellparameter der kalibrierten GLM-Modelle für die fünf untersuchten Bodenbedeckungstypen. Es sind nur diejenigen Variablen (Ave, Min, Max, Std, Range) der 8 Kanäle (B1-B7 & NDVI) aufgelistet, welche in mindestens einem der 5 Modelle verwendet wurden.

Modellparameter	vegetationsfrei	übriges Grünland	Baumbedeckung	Nadelwald	Laubwald
Konstante	3.3657E+00	-8.1180E+00	-4.7137E+00	-2.0094E+01	3.3657E+00
B1_Ave	-1.3140E-02	-5.6440E-03	6.7266E-03	1.1934E-02	-1.3140E-02
B1_Ave <sup>2</sup>	9.1010E-07	1.7083E-06	-1.0480E-07	-3.6790E-07	9.1010E-07
B1_Max	-1.7668E-05	1.7049E-03	-9.3163E-04	1.0809E-03	-1.7668E-05
B1_Max <sup>2</sup>	6.8100E-08	-1.0200E-07	-8.1600E-08	-2.9400E-07	6.8100E-08
B2_Ave	2.1401E-03	1.2330E-03	9.2604E-04	-3.7361E-03	2.1401E-03
B2_Ave <sup>2</sup>	-4.9290E-07	1.3760E-07	-3.8180E-07	1.9230E-07	-4.9290E-07
B2_Max	2.5961E-04	-2.3470E-04	-8.1039E-04	-1.6657E-03	2.5961E-04
B2_Max <sup>2</sup>	-2.4600E-08	4.5000E-09	1.1020E-07	2.0780E-07	-2.4600E-08
B3_Ave	-7.3225E-04	-6.1746E-03	9.5563E-03	-2.5448E-03	-7.3225E-04
B3_Ave <sup>2</sup>	-1.2520E-07	9.7630E-07	-7.8140E-07	1.5160E-06	-1.2520E-07
B3_Max	-7.6610E-04	3.1493E-04	-5.2604E-04	1.2408E-03	-7.6610E-04
B3_Max <sup>2</sup>	4.6300E-08	-9.6000E-09	-3.9000E-08	-1.5600E-07	4.6300E-08
B4_Ave	1.2674E-02	1.3597E-02	-1.7217E-02	-6.2623E-03	1.2674E-02
B4_Ave <sup>2</sup>	-4.8830E-07	-2.8600E-06	7.5160E-07	-1.3920E-06	-4.8830E-07
B4_Max	6.2888E-04	-2.3156E-03	1.7683E-03	-1.4606E-03	6.2888E-04
B4_Max <sup>2</sup>	-9.2300E-08	1.2620E-07	6.4400E-08	2.8830E-07	-9.2300E-08
B5_Ave	-2.5526E-03	-5.8851E-04	-3.2206E-03	5.9755E-03	-2.5526E-03
B5_Ave <sup>2</sup>	5.5840E-07	-2.8800E-07	8.5370E-07	-2.6470E-07	5.5840E-07
B5_Max	1.3857E-04	8.9356E-05	5.2841E-04	1.7571E-04	1.3857E-04
B5_Max <sup>2</sup>	-9.6000E-09	1.2000E-09	-8.2200E-08	-7.1500E-08	-9.6000E-09
B6_Ave	-2.3383E-03	4.5172E-04	7.9006E-03	-5.6156E-03	-2.3383E-03
B6_Ave <sup>2</sup>	1.2300E-08	4.5580E-07	-2.2218E-06	-3.8500E-07	1.2300E-08
B6_Max	-1.9096E-04	8.4801E-04	-8.3373E-04	4.3129E-04	-1.9096E-04
B6_Max <sup>2</sup>	3.8700E-08	-1.0760E-07	1.5530E-07	9.5100E-08	3.8700E-08
B7_Ave	5.3474E-03	-5.2655E-03	1.5579E-04	4.1703E-03	5.3474E-03
B7_Ave <sup>2</sup>	-1.1813E-06	9.6700E-07	5.1810E-07	-7.1270E-07	-1.1813E-06
B7_Max	1.6663E-04	-2.9434E-04	-2.7071E-04	-1.1758E-03	1.6663E-04
B7_Max <sup>2</sup>	-3.2700E-08	6.2900E-08	-9.5000E-09	1.2520E-07	-3.2700E-08
NDVI_Ave	-1.0079E-03	3.1816E-02	4.3961E-04	3.0328E-02	-1.0079E-03
NDVI_Ave <sup>2</sup>	-1.2172E-05	-3.0227E-05	1.3725E-05	-8.7430E-06	-1.2172E-05
NDVI_Max	6.9574E-04	5.2203E-03	-7.4685E-03	2.2886E-02	6.9574E-04
NDVI_Max <sup>2</sup>	-6.6830E-07	3.0974E-06	1.7791E-06	-1.3347E-05	-6.6830E-07
NDVI_Min	2.2348E-03	-1.6486E-02	1.5297E-03	-1.3349E-02	2.2348E-03
NDVI_Min <sup>2</sup>	-1.7370E-07	9.2778E-06	-2.6810E-07	9.5774E-06	-1.7370E-07
NDVI_Range	0.0000E+00	0.0000E+00	0.0000E+00	0.0000E+00	0.0000E+00
NDVI_Range <sup>2</sup>	2.3926E-06	-5.8826E-06	-2.9758E-06	-1.0380E-05	2.3926E-06
NDVI_Std	-5.9608E-03	-1.9667E-02	1.4188E-02	8.4535E-03	-5.9608E-03
NDVI_Std <sup>2</sup>	-1.0149E-05	2.8990E-05	1.0966E-05	7.3816E-06	-1.0149E-05