

EIN ANSATZ ZUR VEGETATIONSERKENNUNG AUS LUFTBILDERN MIT HILFE VON MARKOV-ZUFALLSFELDERN IN VERBINDUNG MIT DER OBERFLÄCHENREKONSTRUKTION

B. Wrobel, A. Krauth,
Technische Hochschule Darmstadt, Institut für Photogrammetrie und Kartographie (Germany)

Internationale Gesellschaft für Photogrammetrie und Fernerkundung
Kommission III, Arbeitsgruppe 3
XVIII ISPRS Congress Vienna, Austria, 9-19 July 1996

KEYWORDS: Vegetation, Recognition, Interpretation, Markov Random Fields, 3D-Surface Data, Multi-Spectral Image Data

ABSTRACT:

An approach is presented for automatic detection of vegetation out of large scale aerial images. The method is based on the Markov Random Field theory. We combine both object recognition and object surface reconstruction by modelling form, colour and semantic information in the 3D object space. In the beginning the tasks segmentation and interpretation are separated: As an low level task image segments are build by texture detection. These segments are then interpreted. A conjunction between image interpretation and object recognition is made by an exchange of information between these tasks. The theory of Markov Random Fields is extended to „Dynamic Markov Random Fields“ which can be used to do both image segmentation and object recognition by the same MRF.

KURZFASSUNG:

Es wird ein Konzept zur differenzierten Vegetationserkennung aus großmaßstäbigen Luftbildern mit Hilfe von Markov-Zufallsfeldern (MRF) vorgestellt, welches die Verfahren der Objekterkennung und der Oberflächenrekonstruktion miteinander über eine 3D-Modellierung von Form, Farbe und Semantik in Wechselwirkung bringt. Zunächst soll die Objekterkennung zweistufig ablaufen. Auf der unteren Ebene werden aufgrund von Texturmerkmalen Segmente gebildet, welche dann durch die obere Ebene Interpretiert werden. Zwischen den Verfahren der Objekterkennung und Objektrekonstruktion soll ein Informations- und Ergebnisaustausch realisiert werden. Die Theorie der MRF wird gedanklich zu dynamischen Zufallsfeldern erweitert, um eine gleichzeitige Segmentierung und Objekterkennung zu ermöglichen.

1. EINLEITUNG

Bisher wurden die Computerverfahren zur Objekt-rekonstruktion und zur Objekterkennung meist getrennt voneinander betrachtet. Die Ergebnisse beider Verfahren können jedoch entscheidend verbessert werden, wenn man sie miteinander kombiniert, d.h. die Verfahren werden über eine 3D-Modellierung von Form, von Farbe und von Semantik in eine gegenseitige Wechselwirkung gebracht.

Unsere Aufgabe ist die differenzierte Erkennung von Vegetation aus großmaßstäbigen Luftbildern für die automatisierte Daten- bzw. Informationserfassung:

- zur Ableitung der Deutschen Grundkarte 1 : 5000 (DGK 5),
- als Grundlage für GIS oder andere Informationssysteme,
- als Hilfsmittel für die Ableitung des Digitalen Landschaftsmodells (DLM) aus dem Digitalen Topographiemodell (DTM) und schließlich
- zur Bereitstellung einer Methode für die Beseitigung des Terrain-Noise.

Die Grundlage unseres Verfahrens beruht auf dem Einsatz von Markov-Zufallsfeldern (Markov Random Fields, MRF) sowohl für die Bildsegmentierung als auch für die Objekterkennung, basierend auf einem Ansatz von MODESTINO/ZHANG [Modestino/Zhang, 1992], welcher von KOCH/KÖSTER [Köster, 1995] weiterentwickelt wurde.

Eine Verbesserung der Interpretationsergebnisse soll dadurch erreicht werden, daß bereits erkannte Objekte als Kontext im Verfahren der Vegetationserkennung verwendet werden.

Durch die Integration der Resultate aus der Objekterkennung in den Vorgang der Oberflächenrekonstruktion sollen ihre bisher noch nicht zufriedenstellend gelösten Probleme, wie die

Modellierung von Unstetigkeiten (Bruchkanten) der Objekt-oberfläche oder Verdeckungen von Bildbereichen gelöst werden. Für bereits erkannte Objekte kann – sofern die Objekthöhe a priori bekannt ist – von der Objekt-oberfläche auf die Erdoberfläche geschlossen werden. Die verbesserten Rekonstruktionsergebnisse (Digitales Oberflächenmodell, Digitales Geländemodell und Orthophoto) stehen dann wiederum für die Bildinterpretation zur Verfügung. Dies führt letztlich zu einem iterativen Vorgang, in welchem sich Oberflächenrekonstruktion und Objekterkennung abwechseln und die Ergebnisse zwischen beiden Verfahren ausgetauscht werden.

2. GRUNDLAGEN

2.1. Markov Zufallsfelder

Als mathematisch-stochastischer Ansatz werden Markov-Zufallsfelder für die Objekterkennung verwendet. Das Grundprinzip der Bildinterpretation mit MRF besteht darin, daß Bildsegmente mit symbolischen Zufallsvariablen verknüpft werden, welche auf einem Nachbarschaftsgraphen definiert sind. Die bedingten Wahrscheinlichkeiten an einem Knoten (Bildsegment) dieses Graphen hängen lediglich von dessen Nachbarknoten ab.

Mit der Theorie der Markov-Zufallsfelder sind wir in der Lage, sowohl Informationen in Form von Merkmalen/Messwerten (Features) flexibel zu verarbeiten, als auch Semantik in Form von Relationen zwischen benachbarten Objekten zu modellieren. Durch die Definition von Markov-Feldern auf Nachbarschaftsgraphen erhält man praktisch automatisch einen

lokalen Kontextrraum für einzelne Objekte. Da die Lösung der Interpretation mit MRF grundsätzlich darin besteht, eine globale Energie zu minimieren, welche als Summe über den gesamten Graphen gebildet wird, und die Eigenschaften (und damit auch die Energie) an einem Einzelknoten weitgehend von den Eigenschaften der Nachbarn dieses Knotens abhängen,

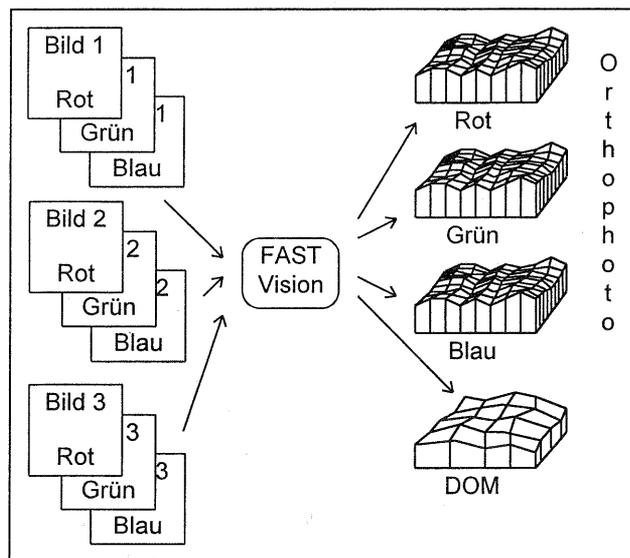


Abbildung 1: Ein- und Ausgabedaten von FAST Vision

betrachtet man gleichzeitig den lokalen und globalen Kontext.

Am Beispiel der Bildinterpretation soll nun die Theorie der MRF in Anlehnung an [Modestino/Zhang, 1992] etwas genauer dargestellt werden: Ausgehend von einem Graphen $G = \{R, E\}$ mit der Knotenmenge $R = \{R_1, R_2, \dots, R_N\}$, wobei jeder Knoten einem Bildsegment entspreche, und der Menge der diese Knoten verbindenden Kanten E , wobei lediglich räumlich benachbarte Knoten durch Kanten verbunden sind, läßt sich ein Nachbarschaftssystem $n = \{n(R_1), n(R_2), \dots, n(R_N)\}$ definieren, wobei $n(R_i)$, $i = 1, 2, \dots, N$, die Menge aller Knoten in R ist. Dabei ist $R_i \notin n(R_i)$ und wenn $R_j \in n(R_i)$ dann gilt $R_i \in n(R_j)$. Assoziiert man mit jedem Knoten R_i aus R eine (symbolische) Zufallsvariable I_i , so bezeichnet man die Menge $I = \{I_1, I_2, \dots, I_N\}$ als Zufallsfeld.

Für Markov-Zufallsfelder müssen daneben noch folgende Eigenschaften erfüllt sein:

- 1.) $P[I] > 0$ für alle Realisierungen von I
- 2.) $P[I_i | I_j]$ für alle R_j wobei $j \neq i$ = $P[I_i | I_j]$ für alle j wobei $R_j \in n(R_i)$

Der zweite Punkt bringt dabei zum Ausdruck, daß die statistischen Eigenschaften an einem bestimmten Knoten im wesentlichen nur von den Eigenschaften der Nachbarknoten abhängen.

Eine wichtige Eigenschaft von Markov Zufallsfeldern ist die, daß ihre Wahrscheinlichkeitsdichte identisch ist mit der Gibbs-Verteilung. Die Theorie der Gibbs-Felder benutzt dem Begriff der Clique, welche eine Untermenge eines Graphen darstellt, wobei in dieser Untermenge jeder Knoten mit allen anderen Knoten durch Kanten verbunden ist.

Bezeichnet man die Menge aller Cliques in G bezüglich des Nachbarschaftssystems n mit $C(G, n)$, so hat die Wahrscheinlichkeitsdichte folgende Gibbs-Verteilung:

$$P[I] = Z^{-1} \exp[-U(I)]$$

wobei

$$U(I) = \sum_{c \in C(G, n)} V_c(I)$$

auch als Energie-Funktion bezeichnet wird und Z lediglich einen Normierungsfaktor darstellt. Die V_c werden im allgemeinen als Cliquenfunktionen bezeichnet und können beliebiger Art sein solange man beachtet, daß sie lediglich von den Knoten der jeweiligen Clique abhängen. Mit Hilfe der Cliquenfunktion wird letztlich das Verhalten des Markov-Zufallsfeldes gesteuert, durch geeignete Wahl der Cliquenfunktion lassen sich Regeln, Vorwissen und Messwerte mit Hilfe der MRF modellieren.

Als wesentlicher Grundgedanke ist zu beachten, daß die Energie, also der Funktionswert einer Cliquenfunktion hoch sein soll, wenn die Wahrscheinlichkeit der Zuordnung gering ist, und der Funktionswert klein sein soll, wenn die Zuordnungen an den Knoten sowohl mit den Messwerten als auch mit dem Vorwissen konsistent sind. Mit dieser Grundregel können beliebige Cliquenfunktionen erstellt werden.

Das Problem der Bildinterpretation kann mit Hilfe von Markov-Zufallsfeldern als Optimierungsproblem angesehen werden: Für ein gegebenes R wird ein Maximales $I_0(R)$ gesucht, wobei dies dann erreicht wird, wenn die gewählten Zuordnungen an den Knoten des Zufallsfeldes sowohl mit den Messungen als auch mit dem Vorwissen bestmöglich konsistent sind.

2.2. Objektoberflächenrekonstruktion (Facetten-Stereosehen)

Das Programmsystem Facetten-Stereosehen (FAST Vision) ist ein objektraumorientiertes Rekonstruktionsverfahren, welches auf einem Finite-Elemente-Ansatz sowohl der Objektoberfläche (DOM) als auch der Objektdichten (Orthophoto) beruht. Mit Hilfe dieses Programms lassen sich gleichzeitig hochaufgelöste DOM und Orthophotos aus (Luft-)Bildern ableiten.

Durch den objektraumorientierten Ansatz ist es insbesondere relativ einfach möglich, zusätzliche Bedingungen einzuführen. Neben Regularisierungsfunktionen können dies insbesondere geometrische Bedingungen wie beispielsweise die Einführung von Bruch- oder Objektkanten als Bearbeitungsgrenzen sein, wodurch letztlich die Finiten-Elemente optimal an die gegebene Situation (Objektoberfläche) angepasst werden können und somit eine maximale Genauigkeit erreicht werden kann.

Als finite Elemente werden üblicherweise quadratische Bilinearflächen verwendet (=Facetten), andere Oberflächenrepräsentationen sind jedoch ebenfalls möglich, z.B. orthogonale Wavelets [Tsay et al., 1996]. Abbildung 1 soll den grundsätzlichen Ansatz von FAST Vision verdeutlichen, weitergehende Literatur findet sich in [Wrobel, 1987], [Tsay, 1996].

2.3. Testdatensatz

Als Testdatensatz wurden 3 Farbinfrarot-Luftbilder im Maßstab 1 : 6 000 ausgewählt und mit einer Auflösung von 15 μm in allen 3 Farbkanälen gescannt. Abbildung 2 zeigt den Stereobereich dieser Luftbilder. Der Bildinhalt kann als typisch für ländlich geprägtes Gebiet angesehen werden. Man kann den Bildinhalt grob in 3 Gebiete unterteilen: Ortslage (ca. 20% der Fläche), landwirtschaftlich genutzte Flächen (ca. 45%) und forstwirtschaftlich genutzte Flächen (ca. 35%).

Für diese Bilder wurden mit Hilfe eines analytischen Auswertesystems die Orientierungsdaten bestimmt. Mit diesen Orientierungsdaten und den Bilddaten kann dann eine automatische Ableitung des DOM und (mehrkanaeligem) Orthophoto mit Hilfe von FAST Vision erfolgen. Dadurch wird eine Erweiterung der Spektralinformation der Bilder um die 3D-Information erreicht.

Die Segmentierung dieser Daten kann dann mit Hilfe eines Algorithmus auf der Basis von Markov-Zufallsfeldern erfolgen, welcher von Koch entwickelt wurde [Köster, 1995]. Zu beachten ist hierbei, daß die Segmentierung nicht nur mit Hilfe der 3 Spektralkanäle erfolgen soll, sondern daß zusätzlich die Höhenunterschiede bzw. „Höhenrauhigkeit“ als vierter Kanal benutzt werden sollen.

Wir erhoffen uns hiervon relativ gute Segmentierungsergebnisse, da wir Textur (Sowohl Farb- als auch Oberflächen-textur) als ein wesentliches Erkennungs- und Unterscheidungsmerkmal von Vegetation betrachten.

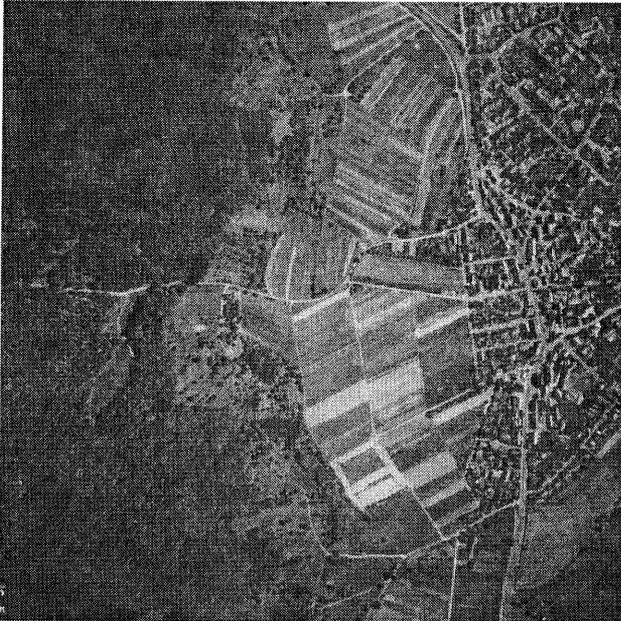


Abbildung 2: Stereobereich des Testdatensatzes (M = 1:6000)

3. MARKOV-ZUFALLSFELDER ALS SEMANTISCHES MODELL ZUR VEGETATIONSERKENNUNG

Bisherige Verfahren der Vegetationserkennung beruhen meist auf kleinmaßstäbigen Bildern, oftmals von Satelliten aufgenommen. Das Standardverfahren zur Vegetationserkennung aus diesen Bildern ist die (interaktive) Multispektralklassifizierung mit Hilfe der Maximum-Likelihood-Funktion, welche in der Praxis eine weite

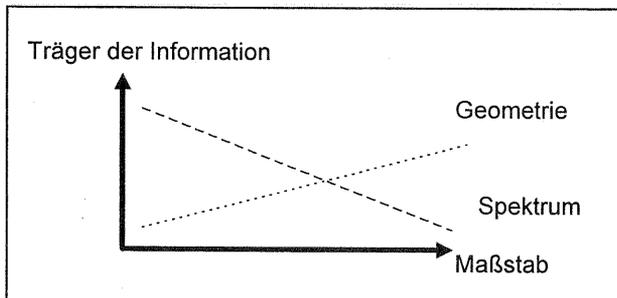


Abbildung 3: Zusammenhang zwischen Bildmaßstab und dem Träger der Information: Geometrie bzw. Spektraleigenschaft eines Objektes

Verbreitung gefunden hat.

Vegetationserkennung aus Luftbildern größerer Maßstäbe ist noch eine Seltenheit, nicht zuletzt deshalb, weil hier die Multispektralklassifizierung an ihre Grenzen stößt und die Klassifizierung mangels geeigneter automatischer Verfahren weitgehend interaktiv durchgeführt werden muß. Dies liegt hauptsächlich im unterschiedlichen Träger der Information in den Bildern begründet (Abbildung 3).

Durch den mit größerem Bildmaßstab immer wichtiger werdenden Geometrie-Eigenschaften eines Objektes benötigt man ein Geometriemodell des zu erkennenden Objektes. Aber auch dann existieren noch eine Vielzahl von Mehrdeutigkeiten, welche durch Berücksichtigung der Objektgeometrie nicht ausgeräumt werden können. Es müssen deshalb auch Relationen und funktionale Zusammenhänge zwischen den Objekten für die Erkennung herangezogen werden, also wird eine eher „ganzheitliche“ Betrachtung des Objekts und seiner Eigenschaften und Funktionen erforderlich [Strat, 1992].

Bei den meisten Gebieten in Mitteleuropa handelt es sich um Kulturlandschaften, d.h. in die natürliche Landschaft/Vegetation wurde und wird vom Menschen eingegriffen. Dadurch entsteht eine Art „Dualismus“ der Vegetation: Sowohl das einzelne Individuum als auch die Gruppen dieser Individuen haben sowohl chaotisch/stochastische Eigenschaften als auch funktional/deterministische Eigenschaften. Für die Modellierung von Vegetation bedeutet dies, daß ein Modell benötigt wird, welches sowohl die deterministischen als auch die stochastischen Eigenschaften beschreiben kann.

Mit den vorgestellten MRF kann dies erreicht werden: Sie ermöglichen die Formulierung von (Nachbarschafts-)Relationen und Beziehungen, die Verarbeitung von Merkmalen einzelner Objekte und Objektgruppierungen sowie die Formulierung von Regelwerken [Modestino/Zhang, 1992][Li, 1994].

4. DYNAMISCHE MARKOV-ZUFALLSFELDER

Objekterkennung in der Photogrammetrie basiert zur Zeit meist auf dem „klassischen“ Bottom-Up-Verfahren: Nachdem das Ausgangsmaterial mit Low-Level-Verfahren vorverarbeitet wurden, wird das Bild aufgrund bestimmter Kriterien – wie beispielsweise Konstanz der Intensitäten – in Gebiete mit homogenen Eigenschaften hinsichtlich dieses Kriteriums unterteilt (Segmentierung). Dabei besteht grundsätzlich das Problem, daß die Segmentierung aufgrund von physikalischen Eigenschaften (z.B. Helligkeit) erfolgt, eigentlich jedoch semantisch zusammenhängende Gebiete segmentiert werden sollen.

Die Entscheidung, welche Gebiete zu semantischen Einheiten zusammengefasst werden können, kann erst getroffen werden, wenn die Objekte bereits erkannt sind. Andererseits ist eine Objekterkennung ohne Segmentierung kaum möglich.

Erste Ansätze, Interpretation und Segmentierung mit Hilfe von MRF gleichzeitig durchzuführen, existieren bereits [Cooper, 1990]: COOPER arbeitet mit sogenannten „Coupled Markov Random Fields“. Dies sind 2 MRF, welche über ihre Knoten miteinander verknüpft werden, wobei eine Ebene für die Bildsegmentierung, die 2. Ebene für die eigentliche Bildinterpretation zuständig ist.

Allgemein bekannt sind Verfahren, welche eine Homogenisierung von Bildsegmentierungen mit Hilfe der MDL (Minimum Description Length) anstreben. Ihr Grundprinzip ist, daß durch Zusammenfassen/Vereinfachen von Gebieten ein Zustand von minimalem Beschreibungsaufwand erreicht wird.

Überträgt man das MDL-Prinzip auf MRF gelangt man zwangsweise zu „dynamischen“ MRF, d.h. Zufallsfelder, die in ihrer Struktur – also sowohl in der Anzahl als auch in der Anordnung ihrer Elemente (Knoten und Kanten bzw. entsprechend Zufallsvariablen und bedingten Dichten) – variabel sind. Sie stellen somit praktisch eine Ergänzung und Erweiterung der bekannten MRF dar. Während man bisher bei

Bei der Verarbeitung von Bildern ist zu bedenken, daß man nicht mit den Objekten selbst, sondern lediglich mit Abbildungen dieser Objekte – den Bilddaten – arbeitet. Ebenso wie die Objekte sind auch die Objekteigenschaften dieser Abbildung unterworfen, d.h. strenggenommen betrachtet man keine Objekteigenschaften, sondern nur die Abbildung der Objekteigenschaften in den Bildern. Durch die weitgehende Formulierung aller Aufgaben im Objektraum, wollen wir versuchen, eine direkte Lösung zu finden. Wir glauben, daß sich dadurch viele Bedingungen, wie beispielsweise die Formulierung von Sichtbarkeiten erheblich vereinfachen lassen, teilweise sogar erst möglich werden.

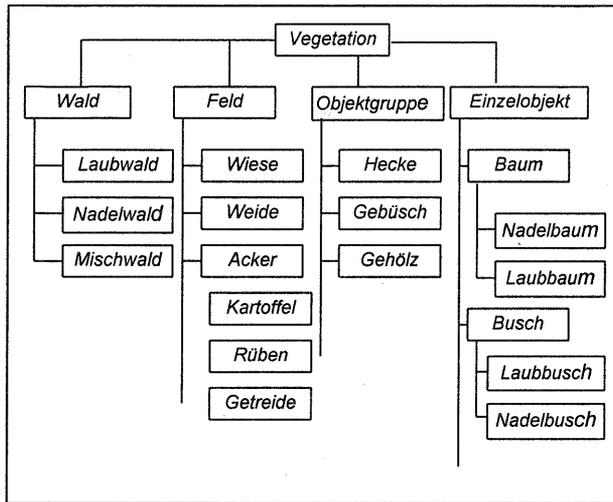


Abbildung 4: Objekthierarchie Vegetation (Ausschnitt)

der Suche nach dem Energieminimum der MRF nur die Zuweisungen der Variablenwerte ändern konnte, ist es mit dynamischen MRF zusätzlich möglich, einzelne Knoten oder Kanten hinzuzufügen oder wegzulassen. Dadurch lassen sich Bildsegmentierung und Objekterkennung gleichzeitig mit nur einem Zufallsfeld bearbeiten.

Die vorhandenen Verfahren und Algorithmen zur Energieminimierung des MRF (z.B. Simulated Annealing) können auch für dynamische MRF verwendet werden. Es ist lediglich zu beachten, daß mit jeder Iteration die Anzahl von Knoten und Kanten variieren kann.

Es ist offensichtlich, daß bei einer fehlerhaften Bildsegmentierung das Ergebnis einer Objekterkennung wahrscheinlich fehlerbehaftet sein wird, wenn keine Möglichkeit besteht, aufgrund von Erkenntnissen des Objekterkennungsvorgangens die Segmentierung zu korrigieren. Arbeitet man mit starren MRF, liegt dann die Vermutung nahe, daß etliche Probleme, welche sich bei der Anwendung von MRF ergeben (langwierige Iterationen, Erreichen von Nebenminima) letztlich darauf zurückzuführen sind, daß das MRF selbst in seiner Struktur fehlerhaft ist. Ob sich diese Probleme mit dynamischen MRF lösen lassen, ist nicht sicher – es ist jedoch wahrscheinlich und sollte deshalb unbedingt geprüft werden.

5. OBJEKTMODELL VEGETATION

Das Objektmodell Vegetation besteht aus geometrischen, physikalischen, strukturellen und semantischen Elementen. Man wird ein Objektmodell nie völlig losgelöst von der Methode betrachten, mit welcher man das Modell zu bearbeiten gedenkt. Man könnte deshalb die Abbildung des Modells auf die verwendete Theorie auch als Bestandteil des Objektmodells auffassen.

Das Objektmodell Vegetation besteht im wesentlichen aus den Eigenschaften der Objekte und den Relationen zwischen den Objekten.

5.1. Objekthierarchie

Ein erster Schritt zum Aufbau eines Objektmodells zur Vegetation ist die Erstellung einer Objekthierarchie, welche ausschnittsweise in Abbildung 4 dargestellt ist.

Eine solche Objekthierarchie eignet sich recht gut als Grundlage für die Umsetzung in C++ Klassenstrukturen. In der Realität trifft man oftmals auf Objekte, welche mehrere Eigenschaften anderer Objekte in sich vereinen, beispielsweise sei hier nur eine Streuobstwiese genannt.

5.2. Objektmerkmale, Erkennungsfaktoren

Für die Erkennung eines Objektes aus Bildern durch einen Interpreten lassen sich bestimmte, relevante Kriterien heranziehen. Diese werden allgemein als Erkennungs- oder auch Interpretationsfaktoren bezeichnet [Albertz, 1991]. Man kann sie grob in 3 Gruppen unterteilen:

1. Radiometrische Erkennungsfaktoren
 - Objekthelligkeit
 - Farbton
 - Farbsättigung
 - Textur
2. Geometrische Erkennungsfaktoren
 - Objektform
 - Objektgröße
 - Objekthöhe
 - relative Lage von Objekten
3. Radiometrisch/Geometrische Erkennungsfaktoren
 - Oberflächentextur
 - Schlagschatten

Am einfachsten zu modellieren sind sicherlich die radiometrischen Erkennungsfaktoren. Sie lassen sich gut durch numerische Werte darstellen und können relativ leicht aus Bildmaterial unterschiedlichster Art extrahiert werden.

Ein Problem stellt dabei immer die Tatsache dar, daß sich alle Erkennungsfaktoren auf „Objekte“ beziehen, d.h. auf semantische Einheiten. Diese Einheiten jedoch sollen ja gerade das Ergebnis der Objekterkennung sein, stehen also zu Beginn der Objekterkennung überhaupt nicht zur Verfügung. Man versucht dies i.a. dadurch zu umgehen, daß die Bilder mit Hilfe von Segmentierungsalgorithmen in Gebiete mit homogenen Eigenschaften unterteilt werden.

Anhand der Erkennungsfaktoren sieht man deutlich, daß die dritte Dimension einen wesentlichen Beitrag zur Objekterkennung liefert. Deshalb soll die Merkmalsextraktion auch auf den Ergebnissen der Objektrekonstruktion (DOM, Orthophoto) erfolgen und nicht, wie bisher üblich, direkt auf den Bilddaten.

Eine weitere Unterscheidung von Erkennungsmerkmalen kann auch dahingehend erfolgen, daß man Merkmale, welche lediglich ein einzelnes Bildsegment betreffen, von solchen, die von mehreren Segmenten abhängig sind, trennt. Typische Beispiele für Merkmale, die lediglich von einem Bildsegment abhängen sind Helligkeit, Größe, Farbe etc. Merkmale, welche von mehreren Segmenten abhängen sind beispielsweise Kontrast oder Höhenunterschied.

5.3. Regeln

Neben Objektmerkmalen dienen im wesentlichen Regeln in Form von sog. „spatial constraints“ dazu, eine zuverlässige Objekterkennung zu erreichen. Für die Vegetation bestehen diese Regeln aus Wissen, welches interaktiv aus den Bildern abgeleitet werden soll. Dieses „räumliche“ Wissen besteht beispielsweise aus Regeln wie

- ein Acker liegt nicht im Ort
 - Äcker sind meist benachbart
 - ein Acker ist nie vollständig von anderen Äckern umgeben
- Es sind auch Ansätze bekannt, welche eine automatische Ableitung einer Wissensbasis ermöglichen [Kristen/Munkelt, 1992], die dort gemachten Erfahrungen zeigen jedoch, daß dies wohl nicht ausreichend ist.

5.4. Umsetzung in MRF-Theorie

Wie bereits angesprochen, besteht das „Objektmodell Vegetation“ im wesentlichen aus Merkmalen und Regeln, wobei man deren Abbildung auf die MRF-Theorie ebenfalls noch zum Objektmodell hinzurechnen kann.

Ein entscheidender Punkt wurde bisher nicht erwähnt: Es genügt nicht, eine gewisse Anzahl von Objektmerkmalen aus den Bildern zu extrahieren und zusammen mit den aufgestellten Regeln mit einem MRF zu verarbeiten. Es muß auch geklärt werden, in welchem Maß eine bestimmte Information (Merkmal, Regel) für die Lösung der Erkennungsaufgabe beiträgt, d.h. man braucht ein (automatisches) Bewertungsverfahren, mit dem man relevante von weniger relevanter Information unterscheiden kann.

Für extrahierte Merkmale bietet sich hier das Verfahren der Hauptkomponententransformation an, welches üblicherweise bei der multispektralen Klassifizierung verwendet wird.

Die Umsetzung der in Kapitel 5.3 beispielhaft aufgezählten Regeln erfolgt mit Hilfe der in Kapitel 2.2 dargestellten Cliquesfunktionen: Cliques, welche nicht den Regeln entsprechen, liefern eine hohe Energie, die Interpretation wird deshalb als relativ schlecht bewertet.

6. GESAMTKONZEPT

Abbildung 5 soll noch einmal das Gesamtkonzept der Vegetationserkennung in Zusammenhang mit der Objektflächenrekonstruktion graphisch verdeutlichen: Ausgehend von sich überlappenden Luftbildern wird mit Hilfe des Programmsystems FAST Vision automatisch ein hochaufgelöstes DOM und Orthophoto abgeleitet. Diese Daten bilden die Grundlage für eine spezialisierte Segmentierung, Merkmalsextraktion und Objekterkennung auf der Basis von MRF, welche nicht – wie bisher üblich – auf den zweidimensionalen Bildern erfolgt, sondern auf den Rekonstruktionsergebnissen (DOM, Orthophoto).

Mit den Ergebnissen dieser Objekterkennung soll dann die Genauigkeit der Objektrekonstruktion verbessert werden, insbesondere durch die Einführung von (potentiellen) Bruchkanten als Zusatzinformation in den Rekonstruktionsvorgang. Die so verbesserten Rekonstruktionsergebnisse stehen dann wiederum der Objekterkennung zur Verfügung.

Da dieses Projekt innerhalb einer DFG-Gruppe angesiedelt ist, ergibt sich in Ergänzung zu den anderen Gruppen im Projekt (Verkehrswege, Gebäude) eine Abdeckung der wesentlichsten Inhalte eines Luftbildes. Die Ergebnisse dieser Gruppen sollen in den Vorgang der Vegetationserkennung einfließen, um eine weitere Verbesserung der Erkennungsrate zu erreichen. Dies soll in Form von vorinterpretierten Gebieten erfolgen, die zusätzliche Kontextinformation für die Vegetationserkennung liefern.

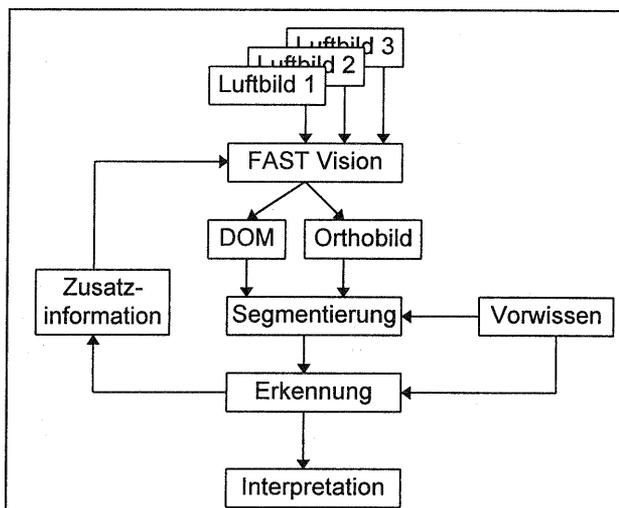


Abbildung 5: Gesamtkonzept der Vegetationserkennung

7. FAZIT

Wir glauben, mit der Methode der MRF für die Vegetationserkennung ein erfolgversprechendes Konzept entwickelt zu haben, welches für die gestellten Aufgaben brauchbare Ergebnisse liefern kann.

Neu an dem Verfahren ist die Verwendung von Oberflächeninformation als Zusatzinformation zur Klassifizierung sowohl als Formtextur als auch in Form von einzelner Objekthöhen (Baumhöhen, Haushöhen). Die Aufgaben Oberflächenrekonstruktion, Merkmalsextraktion und Objekterkennung werden weitgehend auf den Rekonstruktionsergebnissen, d.h. im 3D-Objektraum formuliert.

Eine automatische Vegetationserkennung aus Luftbildern großer Maßstäbe ist noch weitgehend „Neuland“, Markov-Zufallsfelder wurden dafür bisher nicht eingesetzt.

Daß Vegetationserkennung aus großmaßstäbigen Luftbildern mit Hilfe von Objektmodellen durchaus erfolgreich sein kann, belegen die Ergebnisse von Pollock [Pollock, 1994], der eine Erkennungsrate von immerhin 69% für einzelstehende Bäume erreicht, wobei die dabei benutzte Information lediglich aus einem Spektralkanal abgeleitet wurde.

Die Erweiterung der Markov-Zufallsfelder um eine dynamische Komponente läßt eine gleichzeitige Verarbeitung von bisher nacheinander ablaufenden Vorgängen zu.

Letztlich soll eine Wechselwirkung zwischen Objekterkennung und Oberflächenrekonstruktion durch den Austausch der Ergebnisse dieser bisher noch getrennt betrachteten Verfahren erreicht werden.

DANK

Die vorgestellten Arbeiten wurden durch Mittel der Deutschen Forschungsgemeinschaft ermöglicht.

LITERATUR

Chou, P.B., P.R. Cooper, M.J. Swain, C.M. Brown, L.E. Wixson, 1993: *Probabilistic network inference for cooperative high and low level vision*. Chellapa, R., Jain, A.: Markov Random Fields. Academic Press, Boston pp. 211-243.

Cooper, P., 1990: *Parallel Structure Recognition with Uncertainty: Coupled Segmentation and Matching*. ICCV, Osaka. IEEE Computer Society Press.

Köster, M., 1995: *Kontextsensitive Bildinterpretation mit Markoff-Zufallsfeldern*. Dissertation, Bonn.

Kristen, H., Munkelt, O.: *Markov-Feld-basierte Bildinterpretation mit automatisch generierten Datenbasen*. Mustererkennung 1992, 14. DAGM-Symposium 1992, Springer Verlag.

Lee, S.Z., 1994: *Markov Random Field Models in Computer Vision*. Eklundh, Berlin pp. 361-370.

Modestino, J.W., Zhang, J., 1992: *A Markov Random Field Model-Based Approach to Image Interpretation*. IEEE PAMI, 7 (1), pp. 570-585.

Pollock, R. J. 1994: *A Model-Based Approach to Automatically Locating Individual Tree Crowns in High-Resolution Images of Forest Canopies*. 1st International Airborne Remote Sensing Conference and Exhibition, Strasbourg.

Strat, T., 1992: *Natural Object Recognition*. Springer.

Tsay, J.-R., Schnieder, R., Wrobel, B. P., 1996: *Wavelets based object surface reconstruction by FAST Vision*. Intern. Congress of ISPRS, Commission III, WG III/2, Vienna, Austria, 1996.

Tsay, J.-R., 1996: *Wavelets für das Facetten-Stereosehen*. Dissertation TH Darmstadt, Deutsche Geodätische Kommission, Reihe C, Nr. 454, München.

Wrobel, B., 1987: *Facets Stereo Vision (FAST Vision) - A new approach to Computer Vision and to Digital Photogrammetry*. Conference of ISPRS an Fast Processing of Photogrammetric Data, Interlaken, Switzerland.