# Pilotprojekt LB-SNP 2000

Teilprojekt B: Digitale, automatisierte Auswerteverfahren





# Schlussbericht

#### Eidg. Forschungsanstalt WSL

Abteilung Landschaftsinventuren Forschungsbereich Landschaft Zürcherstrasse 111 8903 Birmensdorf

# Remote Sensing Laboratories (RSL)

Geographisches Institut Universität Zürich Winterthurerstrasse 190 8057 Zürich



#### Vertrag

Offerte vom 10. Januar 2002, Auftragserteilung vom 11. Februar 2002 durch GIS-SNP

#### Titel

Pilotprojekt LB-SNP 2000, Teilprojekt B: Digitale, automatisierte Auswerteverfahren

#### Autoren

Dr. Urs Frei, RSL Dr. Tobias Kellenberger, RSL dipl. biol. Christian Ginzler, WSL dipl. geogr. Markus Schwarz, WSL

dipl. geogr. Philippe Meuret, RSL Dr. José Lencinas, pr+sig, CIEFAP

#### Stichworte

Fernerkundung, digitale Photogrammetrie, objektorientierte Bildklassifikation, Bodenbedeckungsklassierung

#### Zusammenfassung

#### Ausgangslage

Nach 1988 fand im August 2000 zum zweiten Mal eine Befliegung des Schweizerischen Nationalparks statt. Bevor eine flächendeckende Auswertung der dabei erhobenen Bilder durchgeführt wird, sollen im Rahmen eines Pilotprojektes die entsprechenden Entscheidungsgrundlagen erarbeitet werden. Im Teilprojekt A, durchgeführt im Jahr 2000, wurden Luftbilder der Testgebiete "Ova Spin" und "Val dal Botsch" manuell interpretiert.

#### Vorgehen

Das hier vorgestellte Teilprojekt B umfasst 3 Schwerpunkte:

- Die digitale Orthophotoherstellung und Luftbild-Mosaikierung f
  ür das Testgebiet "Val dal Botsch". Bei der Orthophotoherstellung wurde insbesondere die Frage abgekl
  ärt, mit welchen Passpunkts
  ätzen welche Genauigkeit erzielt werden kann.
- 2. Die automatisierte, objektorientierte Klassifikation der Ortho-Luftbilder.
- 3. Der Vergleich zwischen den Resultaten aus dem Teilprojekt A mit den Klassifikationsresultaten aus dem vorliegenden Projekt.

Die Orthophotoherstellung und die Klassifikation wurden an den Remote Sensing Laboratories (RSL) des Geographischen Instituts an der Universität Zürich durchgeführt. Um eine grösstmögliche Objektivität beim Resultatvergleich zu gewährleisten, wurde dieser an der Eidg. Forschungsanstalt für Wald, Schnee und Landschaft (WSL) durchgeführt.

#### Resultate

Ca. 70% der signalisierten Passpunkte aus der Befliegung von 1988 können in die Bilder der Befliegung 2000 übertragen werden. Die erreichbare Genauigkeit liegt unter 50cm. Falls eine höhere Genauigkeit (bis 25cm) erforderlich ist, kann diese mit dem nachträglichen Einmessen von zusätzlichen Passpunkten mittels GPS erreicht werden.

Mit der objektorientierten Bildklassifikation ist im Vergleich zur manuellen Interpretation ein geometrisch höherer Detaillierungsgrad zu erreichen. Probleme ergeben sich aber infolge der fehlenden dreidimensionalen Sichtweise (vertikale Strukturen werden kaum erkannt) und in Gebieten mit Schlagschatten.

#### Empfehlungen für das weitere Vorgehen

Auf Grund der Resultate aus dem Teilprojekt A und den hier gemachten Erfahrungen empfehlen wir ein kombiniertes Auswerteverfahren, bei dem sich manuelle Interpretation und automatisierte Klassifikation gegenseitig ergänzen.

Datum	Verantwortlich	Unterschrift	to
29. August 2003	Dr. Urs Frei, RSL		sh

Das Titelbild zeigt einen Ausschnitt aus dem Orthophotomosaik im Gebiet Alp Stabelchod (oben links), sowie denselben Ausschnitt mit dem Resultat der objektorientierten Klassifikation (unten rechts). Weitere Angaben dazu sind im Kapitel 6, Fallbeispiel 1, zu finden.



.....

olihoineenplanditte

# Inhalt

Abb	ildung	en	6
Tabo	ellen .		8
Abk	ürzunş	gen	9
1.	Einle	eitung	10
	1.1.	Ausgangslage	10
	1.2.	Zielsetzungen	10
	1.3.	Gliederung	10
2.	Date	nmaterial	12
	2.1.	Luftbilder	12
	2.2.	Digitale Höhenmodelle	14
	2.3.	Passpunkte	15
		2.3.1. Lagefixpunkte des Bundesamtes für Landestopographie	15
		2.3.2. Signalisierte Passpunkte aus der Befliegung SNP 1988	16
		2.3.3. Signalisierte Kontrollpunkte der Befliegung SNP 2000	17
		2.3.4. Passpunktdatensatz 2002	18
	2.4.	Kartengrundlagen	20
3.	Geon	netrische Vorverarbeitung	21
	3.1.	Zielsetzungen	21
	3.2.	Orthophotomosaik	21
	3.3.	Herstellung eines digitalen Oberflächenmodells (DOM)	23
	3.4.	Genauigkeitsanalyse	24
		3.4.1. Passpunkte	24
		3.4.2. Vergleich DHM-DOM	28
	3.5.	Schlussfolgerungen	29
4.	Digit	ale Bodenbedeckungsklassierung	30
	4.1.	Objektorientierte Klassifikations-Methode	30
		4.1.1. Einleitung	30
		4.1.2. Die Mischpixelproblematik	30
		4.1.3. Der "Salz-und-Pfeffer"-Effekt	31
		4.1.4. Die Bildverarbeitungssoftware eCognition	32
		4.1.5. Die Segmentierung	34
		4.1.6. Klassifikation mit eCognition	35
	4.2.	Vorgehen und Resultate	37



	4.3.	4.2.1. 4.2.2. 4.2.3. 4.2.4. 4.2.5. 4.2.6. 4.2.7. 4.2.8. 4.2.9. Schluss	Verwendete Daten Arbeitsumgebung Segmentierungsschritt LANA - Kartiereinheiten Waldformen Deckungsgrad Wald und Schlussgrad Wald Deckungsgrad der Rasengesellschaften Verteilung aufrechte Bergföhre zu Legföhre Totholzanteile	<ol> <li>39</li> <li>39</li> <li>41</li> <li>45</li> <li>46</li> <li>47</li> <li>47</li> <li>48</li> <li>49</li> </ol>
5.	Gena	uigkeit	sanalyse der automatischen Klassifikation	51
	5.1.	Einleit		51
	5.2.	Method 5.2.1. 5.2.2.	lisches Vorgehen Statistischer Vergleich Terrestrische Kontrolle	51 51 52
	5.3.	Resulta 5.3.1. 5.3.2. 5.3.3. 5.3.4	te LANA-Kartiereinheiten Waldformen Deckungsgrad und Schlussgrad des Waldes Rasendeckungsgrad	53 53 58 59 62
	5 1	Sohluo	Kaschucckungsgrau	64
	5.4.	Scinus		04
6.	Resul	tate un	d Ausblick	67
	6.1.	Resulta 6.1.1. 6.1.2.	Ite       Ite         Herstellung von digitalen Orthobildern       Ite         Digitale Bildklassifikation       Ite	67 67 67
	6.2.	Ausbli	ck	68
Lite	raturv	erzeich	nis	69
Anh	ang A	Beisp	ielkarten	71
		A.1	Kartiereinheit gemäss LANA (1995)	72
		A.2	Waldfläche und Bestandeslückenkartierung	73
		A.3	Waldformen	74
		A.4	Waldformen (vertikale Struktur)	75
		A.5	Deckungsgrad	76
		A.6	Deckungsgrad (gruppierte Klassen)	77
		A.7	Schlussgrad	78
		A.8	Deckungsgrad der Rasengesellschaften	79
Anh	ang B	Kont	rollflächen	80
		В.1 В.2	Ubersicht	80 82



-----

B.3	Kontrollfläche 2 - Walddeckungsgrad und Waldschlussgrad	83
B.4	Kontrollfläche 3 - Walddeckungsgrad und Waldschlussgrad	84
B.5	Kontrollfläche 4 – Waldform	85
B.6	Kontrollfläche 5 - Walddeckungsgrad und Waldschlussgrad	86
B.7	Kontrollfläche 6 - Waldform	87
B.8	Kontrollfläche 7 - Rasendeckungsgrad	88
B.9	Kontrollfläche 8 - Rasendeckungsgrad	89
B.10	Kontrollfläche 9 - LANA-Kartiereinheiten	90
B.11	Kontrollfläche 11 - LANA-Kartiereinheiten	91
B.12	Kontrollfläche 12 - Rasendeckungsgrad	92
B.13	Kontrollfläche 13 – Waldform	93
B.14	Kontrollfläche 14 - Rasendeckungsgrad	94
B.15	Kontrollfläche 15 - Walddeckungsgrad und	
	Waldschlussgrad	95
B.16	Kontrollfläche 16 - LANA-Kartiereinheiten	96
B.17	Kontrollfläche 17 - LANA-Kartiereinheiten	97
B.18	Kontrollfläche 19 – Waldform	98
B.19	Kontrollfläche 20 - LANA-Kartiereinheiten	99
B.20	Kontrollfläche 21 - LANA-Kartiereinheiten	100
B.21	Kontrollfläche 22 - LANA-Kartiereinheiten	101



# Abbildungen

Abbildung 1:	Übersicht der verwendeten Luftbilder	13
Abbildung 2:	Schräglichtschattierte Höhenmodelle DHM25 und DHM10	14
Abbildung 3:	Dokumentation eines Lagefixpunktes (Beispiel)	15
Abbildung 4:	Lageplan der signalisierten Punkte von 1988 im Gebiet "Val dal Botsch"	16
Abbildung 5:	Luftbildmosaik "Val dal Botsch" mit den signalisierten Passpunkten der Befliegung 1988	17
Abbildung 6:	Luftbildmosaik "Val dal Botsch" mit den signalisierten Kontrollpunkten der Befliegung 2000	18
Abbildung 7:	Messkampagne 2002; Einmessen des Messpunktes SNP-136.	19
Abbildung 8:	Luftbildmosaik "Val dal Botsch" mit den im Sommer 2002 neu vermessenen Passpunkten	20
Abbildung 9:	Prinzip des Bündelblockausgleichs	21
Abbildung 10:	Resultierendes Luftbildmosaik "Val dal Botsch"	22
Abbildung 11:	Luftbildmosaik "Val dal Botsch" mit schräglichtschattiertem Oberflächenmodell (DOM04)	23
Abbildung 12:	Theoretisch optimale Passpunktanordnung	24
Abbildung 13:	Grobe Ausrichtung der Luftbilder	25
Abbildung 14:	Verknüpfungspunktverteilung für die Modellbildung	26
Abbildung 15:	Passpunkte "SNP-111" und "SNP-203"	27
Abbildung 16:	Detailaufnahme des Lagefixpunktes SNP-111	28
Abbildung 17:	Höhenlinienvergleich der drei Geländemodelle DHM25, DHM10 und DSM04	29
Abbildung 18:	Unterschied zwischen pixel- und segmentbasierter Analyse an einem einfachen Beispiel	32
Abbildung 19:	Das Prinzip einer Klassifikation mit eCognition im Überblick	33
Abbildung 20:	Beispiel einer 'class hierarchy'	35
Abbildung 21:	Beispiel einer Zugehörigkeitsfunktion in eCognition	36
Abbildung 22:	Zuordnung nach der 'nearest-neighbour'-Methode	36
Abbildung 23:	Wald- / Nichtwaldkartierung	42
Abbildung 24:	Ausschnitt der Kartiereinheiten nach LANA	43
Abbildung 25:	Ausschnitt der Waldflächen und Bestandeslücken	44
Abbildung 26:	Ausschnitt der Waldformen	45
Abbildung 27:	Ausschnitt Deckungsgrad Wald	46
Abbildung 28:	Ausschnitt Schlussgrad Wald	47
Abbildung 29:	Ausschnitt Deckungsgrad der Rasengesellschaften	47



initia and a subsection of the subsection of the

Amountainistation

gittiliggedeneerile

Abbildung 30:	Totholzerkennung: Vergleich 1 m und 20 cm Auflösung	48
Abbildung 31:	Kartierung des liegendes Totholzes	49
Abbildung 32:	Kontrollflächen für die terrestrische Verifikation	53
Abbildung 33:	Kontrollfläche 11 ("LANA-Kartiereinheiten")	55
Abbildung 34:	Kontrollfläche 16 ("LANA-Kartiereinheiten")	56
Abbildung 35:	Kontrollfläche 10 ("LANA-Kartiereinheiten")	57
Abbildung 36:	Kontrollfläche 22 ("LANA-Kartiereinheiten")	57
Abbildung 37:	Kontrollfläche 6 ("Waldformen")	59
Abbildung 38:	Kontrollfläche 4 (Walddeckungsrad und Waldschlussgrad)	62
Abbildung 39:	Kontrollfläche 12 ("Rasendeckungsgrad")	64
Abbildung 40:	Übersicht der Kontrollflächen	80
Abbildung 41:	Legenden	81



Although a second secon

All for the second s

ananasatatamin'n'a

2015/2010/2010/2010/2010

Allenza-sufeeumulliffe

- The second sec

# Tabellen

Technische Angaben zur Befliegung SNP 2000	12
GPS-Auswertung der im Jahre 2002 neu vermessenen Punkte	19
Resultate der Auswertungen mit unterschiedlichen Passpunktgruppen	26
Resultate der Geländehöhenvergleiche	28
Systematik der Standard- und Zusatzmerkmale	38
Übersicht der Segmentierungsebenen	40
Mehrmalige Segmentierung des identischen Ausschnittes mit gleichbleibenden Parametern	41
Klassenbildung	43
Übereinstimmungsmatrix	51
Relative Häufigkeitsverteilung der LANA-Kartiereinheiten für die Klassifikation mit eCognition und die manuelle Interpretation	53
Übereinstimmungsmatrix für die LANA-Kartiereinheiten	54
Relative Häufigkeitsverteilung der Waldformen für die Klassifikation mit eCognition und die manuelle Interpretation	58
Übereinstimmungsmatrix für die Waldformen	58
Relative Häufigkeitsverteilung des Walddeckungsgrades für die Klassifikation mit eCognition und die manuelle Interpretation	59
Übereinstimmungsmatrix für den Walddeckungsgrad	60
Relative Häufigkeitsverteilung des Waldschlussgrades für die Klassifikation mit eCognition und die manuelle Interpretation	60
Übereinstimmungsmatrix für den Waldschlussgrad	61
Relative Häufigkeitsverteilung des Rasendeckungsgrades für die Klassifikation mit eCognition und die manuelle Interpretation	62
Übereinstimmungsmatrix für den Rasendeckungsgrad	63
Mindestflächenkriterien für die manuelle Interpretation	64
Qualitative Beurteilung der Kontrollflächen	65
	Technische Angaben zur Befliegung SNP 2000GPS-Auswertung der im Jahre 2002 neu vermessenen PunkteResultate der Auswertungen mit unterschiedlichenPasspunktgruppenResultate der GeländehöhenvergleicheSystematik der Standard- und ZusatzmerkmaleÜbersicht der SegmentierungsebenenMehrmalige Segmentierung des identischen Ausschnittes mitgleichbleibenden ParameternKlassenbildungÜbereinstimmungsmatrixRelative Häufigkeitsverteilung der LANA-Kartiereinheiten für dieKlassifikation mit eCognition und die manuelle InterpretationÜbereinstimmungsmatrix für die LANA-KartiereinheitenRelative Häufigkeitsverteilung der Waldformen für dieKlassifikation mit eCognition und die manuelle InterpretationÜbereinstimmungsmatrix für die WaldformenÜbereinstimmungsmatrix für den Walddeckungsgrades für dieKlassifikation mit eCognition und die manuelle InterpretationÜbereinstimmungsmatrix für den Waldschlussgrades für dieKlassifikation mit eCognition und die manuelle InterpretationÜbereinstimmungsmatrix für den WaldschlussgradWindestflächenkriterien für die manuelle InterpretationÜbereinstimmungsmatrix für den Rasendeckungsgrades für dieKlassifikation mit eCognition und die manuelle InterpretationÜbereinstimmungsmatrix für den Rasendeckungsgrades für dieKlassifikation mit eCognition und die manuelle InterpretationUbereins



# Abkürzungen

ADS	Airborne Digital Sensor
AGNES	Automatisches GPS-Netz der Schweiz
AP	Arbeitspaket
CIEFAP	Centro de Investigación y Extensión Forestal Andino Patagónico
CIR	Colour Infrared
CLAPA	CLassification Automatisée de Photos Aériennes
CRT	Cathode Ray Tube
DHM	Digitales Höhenmodell
DHM25	Digitales Höhenmodell mit 25 Meter Maschenweite, Produkt des Bun- desamtes für Landestopographie
DOM	Digitales Oberflächenmodell
dpi	dots per inch
EPFL	Ecole Polytechnique Fédérale, Lausanne
ESA	European Space Agency
GIS	Geographisches Informationssystem
GIUZ	Geographisches Institut der Universität Zürich
GPS	Global Positioning System
IPM	Institut de Production Microtechnique (EPFL)
IR	Infrarot
LB	Luftbild
LCD	Liquid Crystal Display
LFP	Lagefixpunktprotokoll
LV03	Landesvermessungsnetz 1903
MB	Megabyte
MEZ	Mitteleuropäische Zeit
NN	nearest neighbour
RMSE	Root Mean Square Error
RSL	Remote Sensing Laboratories
SNP	Schweizerischer Nationalpark
TFT	Thin Film Transistor (Liquid Crystal Display, LCD Technologie)
TIFF	Tagged Image File Format
TM	Thematic Mapper
WSL	Eidgenössische Forschungsanstalt für Wald, Schnee und Landschaft



## 1. Einleitung

#### 1.1. Ausgangslage

Um den Zustand sowie Zustandsveränderungen des Schweizerischen Nationalparks (SNP) flächendeckend festzuhalten, wurden in den Jahren 1988 und 2000 Bildflüge durchgeführt, welche das gesamte Parkgebiet mit Farb- und Infrarot-Luftbildern im Massstab ~1:10'000 abdecken. Diese Bilder wurden bisher nicht ausgewertet.

Angesichts der vielfältigen Möglichkeiten der Luftbildinterpretation und insbesondere im Lichte der neueren Verfahren der digitalen Bildverarbeitung sollen im Rahmen eines Pilotprojektes Entscheidungsgrundlagen für eine flächendeckende Auswertung erarbeitet werden. Zu diesem Zweck wurde das Pilotprojekt zweigeteilt:

- Das Teilprojekt A, durchgeführt im Jahre 2000, zeigte auf, inwieweit die Bodenbedeckung beziehungsweise die Landschaftselemente aus den Infrarot-Luftbildern mittels *analoger* Interpretation bestimmt werden können.
- Im Teilprojekt B, durchgeführt im Jahre 2002, ging es darum, die Möglichkeiten der *digitalen* Bildinterpretationsverfahren auszuloten.

#### 1.2. Zielsetzungen

Im hier beschriebenen Teilprojekt B geht es darum,

- anhand des Testgebietes "Val dal Botsch" Möglichkeiten und Grenzen der digitalen Bildverarbeitung für eine möglichst effiziente Bodenbedeckungskartierung im Gebiet des Schweizerischen Nationalparks zu demonstrieren;
- die Resultate von analogen (Teilprojekt A) und digitalen Verfahren (Teilprojekt B) miteinander zu vergleichen;
- Empfehlungen für eine flächendeckende Auswertung des ganzen Parkgebietes zu erarbeiten.

#### 1.3. Gliederung

Entsprechend dem Projektablauf ist der vorliegende Bericht wie folgt gegliedert:

In Kapitel 2 werden die im Teilprojekt B verwendeten Daten wie Luftbilder, Geländemodelle, Passpunktdatensätze und topographische Karten vorgestellt.

Kapitel 3 behandelt die geometrischen Aspekte der Orthobild-Herstellung. Insbesondere werden die mit unterschiedlichen Passpunktdatensätzen (aus den Bildern der SNP-Befliegung von 1988 übertragene Passpunkte, neu mittels GPS erhobene Passpunkte) zu erreichenden Genauigkeiten untersucht.

Kapitel 4 behandelt die digitale Bodenbedeckungsklassierung. Nach einer allgemeinen Einführung in die objektorientierte Klassifikation werden das konkrete Vorgehen beschrieben und die damit erzielten Resultate präsentiert.

In Kapitel 5werden die Resultate der manuellen Interpretation aus dem Teilprojekt A mit der digitalen Klassifikation aus dem vorliegenden Teilprojekt B verglichen. Dabei ist hervorzuheben, dass die Überprüfung der Resultate personell und institutionell völlig getrennt von der digitalen Klassifikation erfolgte. Damit ist gewährleistet, dass der Vergleich neutral ausgeführt wurde und objektiv ausgefallen ist.



In Kapitel 6 werden die Ergebnisse zusammengefasst und Empfehlungen für das weitere Vorgehen formuliert.

Anhang A enthält die Beispielkarten des Testgebiets, während im Anhang B die Kontrollflächen, welche dem Vergleich manuelle Interpretation - digitale Klassifikation dienten, im Detail dargestellt.



## 2. Datenmaterial

#### 2.1. Luftbilder

Für das vorliegende Projekt wurden vier Farbinfrarotbilder aus der Befliegung SNP 2000 verwendet (siehe Abbildung 1 auf Seite 13). Die wichtigsten technischen Daten zu dieser Befliegung sind in Tabelle 1 zusammengestellt. Weitere Angaben dazu sind im Ergebnisbericht des Teilprojekts A [20] zu finden.

Flugdatum	24. August 2000
Aufnahmezeit	ca. 1015 Uhr MEZ
Flughöhe	~5400 m ü. M.
Kameratyp	Leica RC30 (FMC)
Objektiv	30/4 NAT-S
Objektiv Nr.	17124
Kalibrationszeitpunkt	7. Dezember 1999
Kammerkonstante ( $c_k$ )	303.146 mm
Bildmassstab	1:10'000
Auflösungsvermögen	ca. 63 l/mm
Filmmaterial	Kodak IR 2443

Tabelle 1:Technische Angaben zur Befliegung SNP 2000Quelle: [20]

Die vier Luftbilder wurden durch das Bundesamt für Landestopographie mit einer Auflösung von 14  $\mu$ m digitalisiert. Bei einem durchschnittlichen Bildmassstab von 1:10'000 ergibt dies eine mittlere Bodenauflösung von 0.14 m. Die digitalen Bilder wurden als unkomprimierte TIFF-Dateien mit einer Farbtiefe von 3\*8 Bit gespeichert. Die Datenmenge pro Bild beträgt ca. 818 MB.

Das Kalibrierprotokoll vom 7. Dezember 1999 stand uns ebenfalls zur Verfügung. In diesem Protokoll wird die innere Aufnahmegeometrie der Kamera festgehalten. Es enthält unter anderem Angaben zur Brennweite und zur optischen Verzerrung.



Π

L









#### 2.2. Digitale Höhenmodelle

Die folgenden zwei digitalen Höhenmodelle standen uns zur Verfügung:

- Das Höhenmodell "DHM25" des Bundesamtes für Landestopographie: Das DHM25 liegt in einer Rasterauflösung von 25 Metern und einer Höhenauflösung in Dezimetern vor. Die Höhenwerte wurden durch Digitalisieren der Höhenkurven der Kartenblätter 1:25'000 erfasst und anschliessend in ein regelmässiges Gitternetz umgerechnet.
- Das Höhenmodell "DHM10" des Schweizerischen Nationalparks: Das DHM10 liegt in einer Rasterauflösung von 10 Metern und einer Höhenauflösung in Metern vor. Das DHM10 wurde photogrammetrisch vermessen und nachbearbeitet. Dabei wurden speziell die Bruchkanten erfasst und anschliessend in ein regelmässiges Gitternetz umgerechnet.

Abbildung 2 zeigt einen Ausschnitt der beiden Höhenmodelle und erlaubt einen visuellen Qualitätsvergleich.



DHM25

DHM10

Abbildung 2:Schräglichtschattierte Höhenmodelle DHM25 und DHM10Der abgebildete Ausschnitt zeigt das Gebiet Val dal Botsch - Stabelchod.Beleuchtungsazimut 315°, Elevation 45°. Das DHM10 reicht im Norden<br/>nur bis zur Parkgrenze auf der Krete.



#### 2.3. Passpunkte

Bei Projektbeginn standen drei Passpunktdatensätze zur Verfügung:

- Lagefixpunkte des Bundesamtes für Landestopographie;
- signalisierte Passpunkte aus der Befliegung SNP 1988;
- signalisierte Kontrollpunkte aus der Befliegung SNP 2000.

Ein vierter Passpunktdatensatz musste neu eingemessen werden, damit die Fragestellung im Kapitel 3.4. "Genauigkeitsanalyse" beantwortet werden konnte. Diese vier Passpunktdatensätze werden in den folgenden Abschnitten kurz vorgestellt.

#### 2.3.1. Lagefixpunkte des Bundesamtes für Landestopographie

Die Lagefixpunkte des Bundesamtes für Landestopographie sind dokumentierte und vermessene Fixpunkte im Gelände (siehe Abbildung 3 auf Seite 15). Diese Punkte - auch "Topopunkte" genannt - sind in Fernerkundungsdaten als solche nicht ersichtlich. Sie können aber, je nach geometrischer und radiometrischer Auflösung des Bildes sowie der Präzision der Punktbeschreibung, mit hoher Genauigkeit eingemessen werden.



Abbildung 3: Dokumentation eines Lagefixpunktes (Beispiel)



#### 2.3.2. Signalisierte Passpunkte aus der Befliegung SNP 1988

Für die Befliegung von 1988 wurden die Passpunkte signalisiert. Dabei handelte es sich zum Teil um Lagefixpunkte, zum Teil um zusätzliche markante Punkte im Gelände. Die Originalluftbilder, ein Lageplan (siehe Abbildung 4 auf Seite 16) sowie ein Protokoll der verwendeten Passpunkte standen uns zur Verfügung.











#### 2.3.3.

#### Signalisierte Kontrollpunkte der Befliegung SNP 2000

Vor der Befliegung 2000 wurden Kontrollpunkte im Gebiet "Stabelchod" eingemessen und signalisiert [9]. Diese Punkte waren leider nicht über das ganze Testgebiet verteilt (siehe Abbildung 6 auf Seite 18). Dennoch wurden sie in die Auswertungen mit einbezogen um einen Hinweis auf die Qualität der Geokodierung geben zu können (siehe Kapitel 3.4. "Genauigkeitsanalyse").





Abbildung 6: Luftbildmosaik "Val dal Botsch" mit den signalisierten Kontrollpunkten der Befliegung 2000

2.3.4.

#### Passpunktdatensatz 2002

Für die neu zu vermessenden Passpunkte wurde versucht, auf der Basis von photogrammetrischen Überlegungen eine optimale Passpunktverteilung zu erreichen. Die natürlichen Passpunkte sollten sowohl im Gelände wie auch im Luftbild gut erkennbar sein. Die Planungsergebnisse wurden mit dem Verantwortlichen des Schweizerischen Nationalparks besprochen und den aktuellen Rahmenbedingungen (Wildverteilung, Geländezugänglichkeit) angepasst [8]. Das Einmessen der natürli-Passpunkte erfolgte chen in einer zweitägigen Messkampagne (siehe Abbildung 7 auf Seite 19). Dabei mussten noch während der Messkampagne kleinere Korrekturen betreffend einzumessender Punkte gemacht werden, denn das Wild hatte sich im geplanten Messgebiet verschoben. Die resultierende Passpunktverteilung hat nun im Nordosten und im Nordwesten eine Lücke (siehe Abbildung 8 auf Seite 20). Die Passpunkte wurden mit differentiellem GPS eingemessen und ausgewertet. Die Resultate und erreichten Genauigkeiten sind in der Tabelle 2 auf Seite 19 zusammengetragen worden. Alle Messungen erfolgten auf der Basis der Landesvermessung 1903 (LV03). Dies ermöglicht den direkten Vergleich mit den Daten aus der Befliegung von1988.





-



Abbildung 7: Messkampagne 2002; Einmessen des Messpunktes SNP-136

Manager Ist No.	Land	deskoordinaten	[ <i>m</i> ]	Genauigkeit [m]			
messpunkt-ivr.	x	у	z	horizontal	vertikal	RMSE <sup>a</sup>	
SNP-111	814136.478	174248.452	2513.678	0.003	0.008	0.010	
SNP-115	814490.349	173192.050	2282.466	0.002	0.006	0.006	
SNP-132	814558.952	173167.485	2289.675	0.002	0.005	0.008	
SNP-136	814867.689	172505.460	2119.997	0.006	0.012	0.013	
SNP-145	812569.931	171750.877	1844.025	0.001	0.002	0.005	
SNP-146	812630.934	171773.161	1843.846	0.003	0.003	0.006	
SNP-147	814497.158	170920.487	1914.323	0.005	0.011	0.010	
SNP-148	814482.307	171039.403	1904.183	0.002	0.008	0.006	
SNP-149	814421.583	171307.182	1906.903	0.006	0.012	0.006	
SNP-150	814871.256	172563.488	2155.005	0.007	0.014	0.013	
SNP-151	814262.424	174381.547	2572.711	0.002	0.006	0.006	
SNP-152	814263.596	174289.968	2534.652	0.005	0.015	0.009	
SNP-155	813141.520	172677.083	2206.603	0.001	0.002	0.005	
SNP-164	813583.970	171539.269	1885.776	0.013	0.024	0.012	
SNP-201	814486.143	173521.239	2335.728	0.002	0.004	0.008	
SNP-202	814380.714	173155.920	2308.774	0.002	0.006	0.008	
SNP-203	814379.037	173240.515	2306.223	0.003	0.008	0.009	
SNP-210	813141.039	172673.169	2206.501	0.001	0.002	0.004	
Basis-001	812098.15	171791.80	1798.84	-	-	-	

a. Root Mean Square Error (RMSE) = Quadratwurzel des mittleren quadratischen Fehlers

Tabelle 2: GPS-Auswertung der im Jahre 2002 neu vermessenen Punkte







## 2.4. Kartengrundlagen

Als allgemeine Übersicht des Gebietes "Val dal Botsch" dienten zwei Kartenblätter der Landeskarte der Schweiz im Massstab 1:25'000. Es sind dies die Blätter 1218 "Zernez" und 1219 "S-Charl".



# 3. Geometrische Vorverarbeitung

#### 3.1. Zielsetzungen

Das Ziel des Arbeitspaketes "Geometrie" war, die IR-Luftbilder ins Koordinatensystem der Schweizerischen Landesvermessung zu transformieren. Dabei sollte die Zentralprojektion der Luftbilder in eine Orthogonalprojektion umgewandelt werden.

Die resultierenden Orthophotos mussten anschliessend zu einem einheitlichen Datensatz zusammengefügt werden. Das orthorektifizierte Luftbildmosaik sollte als Basis für die Bodenbedeckungsklassierung genutzt werden.

Es sollte weiter der Frage nachgegangen werden, mit welchen Passpunkten (Lagefixpunkte / signalisierte Passpunkte der Befliegung 1988 / mit GPS eingemessene Punkte) welche geometrische Genauigkeit erreicht werden kann.

### 3.2. Orthophotomosaik

Um die Zentralprojektion eines Luftbildes in eine Orthogonalprojektion umzurechnen, müssen die Angaben eines Luftbildes wie Projektionszentrum und Verkippungswinkel (Lage der Kamera) bekannt sein. Dies wird auch als äussere Orientierung bezeichnet. Gleichzeitig muss auch die sogenannte innere Orientierung bekannt sein. Diese ist, wie im Kapitel 2.1. beschrieben, im Kalibrierprotokoll festgehalten. Zur Generierung eines Orthophotos wird zusätzlich ein Geländemodell benötigt, dass in der gewünschten Referenzgeometrie vorliegt.

Zu diesem Zweck wurden die Luftbilder auf einer digitalen Photogrammetriestation orientiert und ausgewertet (siehe Kapitel 4.4. 'Genauigkeitsanalyse'). Die Orientierung erfolgte mit der Methode des Bündelblockausgleichs (siehe Abbildung 9 auf Seite 21).



Abbildung 9: Prinzip des Bündelblockausgleichs Quelle: [11]



Dabei werden die äusseren Orientierungselemente der Strahlenbündel des Blockverbandes für alle Bilder gleichzeitig bestimmt. Als Informationen stehen dafür die Bildkoordinaten der Verknüpfungspunkte und die Passpunkte, auch Vollpasspunkte genannt, mit den entsprechenden Bild- und geodätischen Koordinaten zur Verfügung. Ein Verknüpfungspunkt ist ein Bildmerkmal, das in mehr als einem Bild sichtbar und eingemessen ist.

Die Bildparameter der besten Ausgleichung (siehe Kapitel 4.4.) wurden zur Generierung der Orthophotos verwendet. Die Geocodierung der einzelnen Luftbilder basiert auf einer Rückwärtstransformation und geht von einer regelmässigen Rasterstruktur der Referenzgeometrie aus. In diesem Fall bildete das Schweizerische Landeskoordinatensystem die Referenzgeometrie. Die Orthophotos wurden auf Rasterweiten von je 1 m und 0.2 m umgerechnet. Die Berechnung der Helligkeitswerte erfolgte dabei mittels bilinearer Interpolation. Die Lagegenauigkeit der Orthobilder liegt - bedingt durch Höhenfehler des verwendeten DHM10 - in der Grössenordnung von 1 m bis 1.5 m.

Nun mussten die vier Orthobilder zu einem Mosaik zusammengefügt werden. War ein Bildelement des resultierenden Mosaiks mit Bildinformation aus mehr als einem Orthobild zu belegen, so wurde das mit dem kleinsten Abstand zum korrespondierenden Bildzentrum genommen. Dadurch konnte die geometrische Ungenauigkeit, die durch ungenaue Korrektur der Radialverzerrung entsteht (Höhenfehler) minimiert werden. Es resultierten zwei Luftbildmosaike (1 m und 0.2m Rasterweite), die für die Bodenbedeckungsklassierung zur Verfügung gestellt wurden (siehe Abbildung 10 auf Seite 22).



Abbildung 10: Resultierendes Luftbildmosaik "Val dal Botsch"



## 3.3. Herstellung eines digitalen Oberflächenmodells (DOM)

Die Lagegenauigkeit in einem Orthophoto wird neben der Bündelblockausgleichung auch noch durch das verwendete Geländemodell beeinflusst. Grundsätzlich ist es denkbar, dass jeder einzelne Bildpunkt eingemessen und korrekt transformiert wird. Dies wird aber schon rein aus Kostengründen nicht gemacht.

Der zu erwartende Lagefehler bei einem bestimmten Höhenfehler (im verwendeten Geländemodell) ist abhängig von der Lage des Bildpunktes gegenüber dem Bildzentrum. Solche Lagefehler sind auf Orthobildern, zum Beispiel an Waldrändern, gut ersichtlich. Geht man davon aus, dass die Geometrie der abgebildeten Oberfläche genau bekannt ist, so ergeben sich auch keine Lagefehler durch Höhenfehler. Dies bedeutet aber, dass jetzt nicht mehr von einem Geländemodell (DHM) sondern von einem Oberflächenmodell (DOM) gesprochen wird.

Mit dem Verfahren der digitalen Bildkorrelation können nur Oberflächenmodelle im Überdeckungsberreich von zwei Luftbildern berechnet werden. Das heisst, wenn das gesamte Testgebiet "Val dal Botsch" mit einem DOM abgedeckt werden müsste, noch vier weitere Luftbilder ausgewertet werden müssten. Dies wurde hier nicht ausgeführt. Es wurde ein DOM mit einer Rasterweite von 4m mittels automatischer Bildkorrelation gerechnet (siehe Abbildung 11 auf Seite 23). Der Übergang von bewaldetem zu nichtbewaldetem Gebiet ist in der Abbildung 11 gut ersichtlich. Das DOM04 stellt im Vergleich zu den vorhandenen DHM's (siehe Abbildung 2 auf Seite 14) somit das genaueste Höhenmodell dar.



Abbildung 11: Luftbildmosaik "Val dal Botsch" mit schräglichtschattiertem Oberflächenmodell (DOM04)



#### 3.4. Genauigkeitsanalyse

Die Lagegenauigkeit in der Photogrammetrie wird durch die Qualität der verwendeten Passpunkte sowie durch das verwendete Geländemodell bzw. Oberflächenmodell beeinflusst.

#### 3.4.1. Passpunkte

Um die Fragestellung, mit welchen Passpunkten welche geometrische Genauigkeit erreicht werden kann zu beantworten, muss eine Testumgebung definiert werden. Gleichzeitig konnte auch der Frage nachgegangen werden, was eine Passpunktverdichtung bringen könnte. In der Photogrammetrie sind die Verfahren, die zu einer optimalen Auswertung führen, bekannt. Auf eine theoretische Erläuterung wird hier verzichtet und auf die Fachliteratur verwiesen [11]. Zum Verständnis des Vorgehens werden nun in der Folge einzelne Arbeitsschritte erläutert.



Abbildung 12: Theoretisch optimale Passpunktanordnung

Einer der wichtigen Einflussfaktoren, der die erzielbare Genauigkeit einer Luftbildauswertung beeinflusst, ist die Verteilung der Passpunkte und die Überdeckungsverhältnisse sowohl in Flugrichtung wie auch quer zur Flugachse. Hier wird dabei von Längs- und Querüberdeckung gesprochen, wobei die erste Prozentzahl jeweils die Längs- und die zweite die Querüberdeckung definiert. Bei der Auswertung von Bildflügen geht man von einem minimalen 60/20% Überdeckungsverhältnis aus. Steigt der Überdeckungsgrad auf 80/60% so ist mit einer Verdoppelung der erzielbaren Genauigkeit zu rechnen. In der Befliegung 2000 sind die Bedingungen für eine gute Auswertung gegeben, denn es ist ein 75/40% Überdeckungsverhältnis im Testgebiet anzutreffen.







Die Theorie und die Realität klaffen oft auseinander, wird nur schon die Passpunktverteilung in 'Abbildung 8' auf Seite 20 genüber der theoretischen optimalen Anordnung (siehe Abbildung 12 auf Seite 24) verglichen. Auf der Basis der vorhandenen Passpunktgruppen (siehe Kapitel 3.3. 'Passpunkte') konnten nun vier unterschiedliche Auswertungen erfolgen.

In der Photogrammetrie können grössere Bildverbände mit wenig Passpunkten ausgewertet werden. Zu diesem Zweck werden die einzelnen Luftbilder durch das Einmessen von Verknüpfungspunkten zu einem stabilen Blockverband zusammengehalten (siehe Abbildung 9 auf Seite 21). Da aber das Auffinden und Einmessen von Punkten auch einer gewissen Toleranz unterliegt, wurde zuerst ein Basismodell, bestehend aus reinen Verknüpfungspunkten, generiert und anschliessend für alle unterschiedlichen Auswerteverfahren dupliziert (siehe Abbildung 14 auf Seite 26). Somit wurde sichergestellt, dass alle die gleiche Testanordnungen haben und von nun an nur noch der Einfluss der Passpunkte zum Tragen kommt.





Abbildung 14: Verknüpfungspunktverteilung für die Modellbildung

In den duplizierten Basismodellen wurden nun die jeweiligen Passpunktgruppen eingemessen und das Modell ausgewertet. Die erzielten Resultate sind in der Tabelle 3 auf Seite 26 festgehalten. Die Variationen beruhen nur noch auf dem Einmessen der jeweiligen Passpunkte und der ändernden Statistik, denn nicht jede Auswertung hat die gleiche Anzahl eingemessener Punkte.

Auswartung mit	RMSE der Modellpunkte			RMSE der Kontrollpunkte		
Auswertung mit	x [m]	y [m]	z [m]	x [m]	y [m]	z [m]
neu vermessenen natürlichen Passpunkten 2002	0.115	0.058	0.032	0.099	0.152	0.259
übertragenen Passpunkten aus der Befliegung 1988	0.238	0.298	0.124	0.146	0.220	0.302
vereinten Passpunkten aus 1988 und 2002	0.189	0.112	0.068	0.059	0.146	0.292
vereinten Passpunkten aus 1988, 2002 und Kontrollpkt.	0.170	0.108	0.062			

Tabelle 3: Resultate der Auswertungen mit unterschiedlichen Passpunktgruppen

Die erzielten Resultate belegen, dass Passpunkte, die für einen bestehenden Bildflug nachträglich eingemessen werden das beste Resultat liefern. Die erwartete Genauigkeit - RMSE der Kontrollpunkte im Subpixelbereich - wird erfüllt.

Bei einer sorgfältigen Übertragung von Passpunkten aus einer anderen Befliegung (hier die Befliegung von 1988) mit gut signalisierten und dokumentierten Passpunkten wurde eine Lagegenauigkeit der Kontrollpunkte von unter 25cm erreicht. Es ist



aber darauf hinzuweisen, dass je nach Art und Lage der signalisierten Punkte auch grössere Abweichungen möglich sind.

Durch eine geeignete Passpunktverdichtung kann eine Auswertung wesentlich verbessert werden; im vorliegenden Beispiel bis zu einer 50% höheren Genauigkeit gegenüber der reinen Auswertung mit den Passpunkten aus der Befliegung 1988.

Die RMSE der Kontrollpunkte belegen, dass keine der Auswertungen einen grundsätzlichen Fehler beinhaltet. Weitergehende Aussagen sind mit der Anzahl Punkte und deren Verteilung im Modell nicht angebracht.

Die Resultate sind aber auch auf der Basis des Luftbildmaterials, in diesem Fall, auf der Basis des digitalen Luftbildes und der zur Verfügung stehenden Passpunkte zu sehen. Um die Relationen aufzuzeigen, wird ein Lagefixpunkt einem natürlichen Passpunkt aus der Feldkampagne 2002 gegenübergestellt.



Passpunkt SNP-111



Passpunkt SNP-203

Abbildung 15: Passpunkte "SNP-111" und "SNP-203"

Es handelt sich hier um Passpunkte die mit GPS eingemessen wurden. Wie unschwer zu erkennen ist, werden diese Punkte nie mit der gleichen Präzision eingemessen werden können (siehe Abbildung 15). Die Situation für den Passpunkt SNP-111 kann aber mit einer ausführlicheren Dokumentation verbessert werden, z.B. durch eine Detailaufnahme im Gelände (siehe Abbildung 16 auf Seite 28).





Abbildung 16: Detailaufnahme des Lagefixpunktes SNP-111

3.4.2. Vergleich DHM-DOM

Da die Lagegenauigkeit eines Orthophotos auch vom Gelände abhängig ist, stellt sich nun die Frage, wie genau die zur Verfügung stehenden DHMs und das DOM04 sind. Im vorliegenden Fall ging man davon aus, dass das digitale Oberflächenmodell mit einer Genauigkeit von 1.5 Promille der Flughöhe über Grund gemessen werden kann (siehe Bericht Teilprojekt A, 2000). Dies ergibt im Testgebiet eine Höhengenauigkeit von 0.3-0.45 Metern. Im Testgebiet "Val dal Botsch" wurde nun angenommen, dass die im Bündelblockausgleich berechneten Punkte richtig sind ( 0.5m). Nun wurden die drei Höhenmodelle auf der Basis der ausgewerteten Punkte verglichen. Dies ist auch für das DOM zulässig, denn es sind alles Bodenpunkte, d.h. es sind Geländehöhen ohne Vegetation eingemessen worden.

Vermessene Punkte minus	Anzahl Punkte	RMS [m]
Oberflächenmodell (DOM04)	77	1.4837
Geländemodell 10 (DHM10)	95	2.9903
Geländemodell 25 (DHM25)	95	7.9146

Tabelle 4: Resultate der Geländehöhenvergleiche

Das Resultat, das in Tabelle 4 auf Seite 28 gezeigt wird, ist nicht weiter erstaunlich. Die Unterschiede in der Rasterweite erklären in diesem Gelände schon einige Höhenfehler (siehe Abbildung 17 auf Seite 29). Doch was heisst das für die Orthorektifizierung?

Bei einer Brennweite von 305mm hat ein Höhenfehler von 10m im Bildhauptpunkt keinen Einfluss, in der äussersten Bilddiagonale erzeugt dieser einen Lagefehler von fast 5 Metern. Das bedeutet, dass das DHM25 in unserem Fall ungeeignet ist, denn ein Höhenfehler von 7m erzeugt einen Lagefehler von ca. 3.5 m und auf halber Bilddiagonale immer noch einen Fehler von 1.75m. Ein Geländemodell der Qualität



des verwendeten DHM10 sollte für die Generierung von Orthobildern mit einer Bodenauflösung von 0.2 m verwendet werden. Denn hier entsteht auf halber Bilddiagonale immer noch ein Lagefehler von ca. 0.75m. Dies ist bei einem Mosaik im 1m Raster genügend. Bei einem Raster von 0.2m ist der Fehler schon etliche Pixel gross. Ein DOM wäre gut, doch müssen diese oft stark nachbearbeitet werden, so dass sich die Kosten nur für Gebiete von speziellem Interesse rechtfertigen lassen.



Höhenkurven im 10m Intervall

rot: DHM25 grün: DHM10 gelb: DSM04

Abbildung 17: Höhenlinienvergleich der drei Geländemodelle DHM25, DHM10 und DSM04

#### Schlussfolgerungen

- Passpunkte, die für ein gegebenes Projekt signalisiert oder nach der Befliegung eingemessen werden, erzielen im vorliegenden Fall die höhere Genauigkeit als mit Übertragen von Passpunkten aus anderen signalisierten Befliegungen. Dabei sind Genauigkeitswerte im Subpixelbereich zu erzielen.
- Gemäss den hier gemachten Erfahrungen dürften ca. 70% der signalisierten Passpunkte aus der Befliegung 1988 für die Auswertung der Bilder aus der Befliegung 2000 nutzbar sein. Deren Lagegenauigkeit dürfte gemäss den hier gemachten Erfahrungen in den meisten Fällen unter 50cm liegen.
- Mit einer nachträglichen Verdichtung der Passpunkte in einem Gebiet von speziellem Interesse durch zusätzliche, mit GPS eingemessene Passpunkte, kann die ursprüngliche Genauigkeit um bis zu 50% gesteigert werden.
- Ist kein Geländemodell mit genügender Qualität vorhanden, können die bei der Auswertung erzielten Genauigkeiten nicht in ein Orthophoto transferiert werden. Allgemeine Aussagen sind hier schwierig, denn die Geländeform, die Rasterweite, Interpolationsalgorithmen, Kamerabrennweite etc. spielen eine Rolle. Bei der Verwendung vom DHM25 ist mit diesen Datengrundlagen ein RMSE von mehreren Metern (2 - 3.5m) für das Orthophoto zu erwarten.





3.5.

# 4. Digitale Bodenbedeckungsklassierung

In einem ersten Schritt wird die angewandte digitale Klassifikationsmethode erläutert (Kapitel 4.1.). Ebenso werden die Vorteile einer objektorientierten gegenüber einer pixelbasierten digitalen Methode diskutiert. Die Klassifikationen selber werden in Kapitel 4.2. beschrieben. Sie lehnen sich, auch aus Gründen der Vergleichbarkeit, an das Teilprojekt A an. Die Verifizierung der Klassifikationen ist in Kapitel 5. nachzulesen.

## 4.1. Objektorientierte Klassifikations-Methode

#### 4.1.1. Einleitung

Sehr hochauflösende Fernerkundungsdaten von Bodenbedeckungen waren über Jahrzehnte hinweg nur als analoge Luftbilder erhältlich. Die rasante Entwicklung der photovoltaischen Sensortechnik während der letzten Jahre sowie das Arbeiten mit digitalisierten Luftbildern erlauben heute aber auch eine digitale Datenerfassung mit Pixelauflösungen bis in den Dezimeterbereich (z.B. ADS40<sup>1</sup> Flugzeugscanner, IKONOS Satellitendaten mit 1 m oder Quickbird Satellitendaten mit 0.6 m Auflösung) [6]. Es stehen immer hochwertigere und höher aufgelöste Daten für verschiedene Zwecke zur Verfügung. Der Informationsgehalt der Daten nimmt ständig zu. Die Vorteile solcher hochaufgelösten Daten sind z.B. das geringere Mischpixelproblem (Kapitel 4.1.2.) und die einfachere visuelle Interpretierbarkeit, da Details besser erkennbar sind. Dieser Detailreichtum wirft aber auch neue Probleme bei der digitalen Verarbeitung und Klassifizierung der Daten auf. Die computergestützte Klassifikation wird komplexer. Die digitale Auswertemethodik hat mit der Entwicklung der Sensortechnik vorerst nicht Schritt halten können [6]. Die herkömmlichen, pixelbasierten Klassifikationsansätze stossen zunehmend an ihre Grenzen. Um die neuen Herausforderungen in der Auswertung zu bewältigen, sind innovative Ansätze erforderlich, denn Objektform und Nachbarschaftsbeziehungen sind ebenso wichtige Merkmale bestimmter Bodenbedeckungsformen wie die Grauwerte (Spektralinformationen) selber. Eine Lösung zu diesem Problemkreis können neue Auswertungsmethoden wie die Bildsegmentierung, neuronale Netze oder 'fuzzy sets' bieten. Für Fernerkundungsanwendungen ist die objekt- und damit segmentbasierte Software *eCognition* im Moment die vielversprechendste Lösung, die kommerziell erhältlich ist [17].

#### 4.1.2. Die Mischpixelproblematik<sup>2</sup>

Die Definition eines Mischpixels ist direkt abhängig von der Fläche des zu bestimmenden Geländeobjektes ('object of interest') und damit abhängig von der Skalenebene, die der Auswertung zugrunde liegt. In der Natur gibt es keine spektral "reine" Oberflächen. Was bei einer Auflösung im Meterbereich homogen erscheint, kann sich bei einer Auflösung im Dezimeterbereich als sehr heterogen erweisen. Ein Beispiel: Ein Waldbestand von 2 Hektaren wird durch 22 Landsat TM-Satellitenpixel abgebildet. Im Falle des verwendeten digitalisierten Luftbildes mit 1 m Auflösung wird dieser Waldbestand durch 20'000 Pixel dargestellt. Um das 'object of



<sup>1. &#</sup>x27;ADS40, Airborne Digital Sensor' von Leica Geosystems

<sup>2.</sup> Die Ausführungen in diesem Kapitel beruhen weitgehend auf [6].

interest' "Waldbestand" daraus herzuleiten, ist eine pixelweise Klassifizierung nicht mehr anwendbar. Der Wald hat sich in seine Strukturelemente (Kronenbereiche, Schattenbereiche zwischen den Bäumen, etc.) aufgelöst und ist allein spektral nicht mehr identifizierbar.

Solange das betrachtete Objekt vom Massstab her mit der Pixelgrösse harmoniert, d.h. die einzelnen Pixel spektral "reine" Vertreter ihrer Klasse darstellen, kommt die klassische Pixelanalyse problemlos mit der Klassifikation zurecht. Als Faustregel kann gelten, dass, wenn die zu bestimmenden geophysischen Geländeobjekte im Durchschnitt mit weniger als zehn Pixel repräsentiert werden, das Problem der Randpixel dominant wird. Diese sind als Mischpixel immer zusammengesetzt aus dem Signal benachbarter Objekte. Die Lösung dieses Problems wurde in der Erhöhung der Anzahl Pixel pro Objekt gesehen. Dies führte zur Entwicklung geometrisch höher auflösender Sensoren mit dem Erfolg einer deutlich verbesserten visuellen Detailerkennbarkeit.

Das Mischpixelproblem kann mit Hilfe einer objektbasierten Bildanalyse reduziert werden, da sie sich auf eine lokale "kohärente/homogene" Pixelgruppe oder auf ein sogenanntes "Bildobjekt" stützt. Zusätzlich kann das Bildobjekt den Kontext (z.B. die Topologie) der Pixelgruppe berücksichtigen. Dies ist ein grosser Vorteil, denn in den meisten Fällen wird diejenige Information, welche für das Verständnis eines Bildes wichtig ist, nicht nur durch ein Pixel repräsentiert sondern durch mehrere aussagekräftige Bildobjekte und ihre wechselseitigen Beziehungen [3].

#### 4.1.3. Der "Salz-und-Pfeffer"-Effekt<sup>3</sup>

Eine pixelbasierte Klassifikation bewirkt einen "Salz-und-Pfeffer"-Effekt im Bild, denn für jedes Pixel wird die Klassenzugehörigkeit unabhängig von der Nachbarschaft berechnet. Liegt ein Pixel knapp unter einem spektralen Schwellenwert, so wird es einer anderen Klasse zugeordnet als seine Umgebung. Es ergeben sich dadurch keine klar abgegrenzte Formen sinnvoller Landschaftseinheiten, sondern es entstehen viele Einzelpixel. In der Planung ist diese Art von Erscheinung störend. Planer fordern die aus der GIS-Welt gewohnten, klar abgegrenzten Objekte. Dies kann zwar mit Hilfe von Filteranwendungen erreicht werden, die ursprüngliche Information wird dabei aber nicht berücksichtigt. Statt die Pixel rein statistisch zu betrachten, gehen neue Ansätze von der Annahme aus, dass eines dieser Bildelemente mit einer bestimmten Wahrscheinlichkeit zur gleichen Klasse wie sein Nachbarpixel gehört. Der Grundgedanke ist, ein Bild in Segmente (räumlich zusammenhängende Gruppen von Pixeln) zu unterteilen, die in der realen Welt eine Bedeutung haben. Solche segmentbasierte Klassifikationen weisen keinen "Salzund-Pfeffer"-Effekt auf und benötigen auch keine Filteranwendungen. Abbildung 18 auf Seite 32 veranschaulicht den Unterschied zwischen der segmentbasierten und der pixelbasierten Klassifikation.

<sup>3.</sup> Die Ausführungen in diesem Kapitel beruhen weitgehend auf [2] und [3].







#### 4.1.4. Die Bildverarbeitungssoftware *eCognition*<sup>4</sup>

eCognition<sup>TM</sup> ist eine von der Firma Definiens AG (München) entwickelte Software für Bildanalyse. Definiens geht mit eCognition neue Wege in der Bildinterpretation, indem sie die menschliche Wahrnehmung als Vorbild nimmt. Beim Menschen ist das Bildverständnis ein sehr komplexer kognitiver Prozess mit zahlreichen Schritten zwischen den visuellen Eingangsdaten, der Mustererkennung und den Erinnerungen. Das eigentliche Sehen bildet mit dem Erfassen der visuellen Eingangsdaten (Spektralinformationen) nur einen ersten Schritt. Beim weiteren Wahrnehmungsprozess geht das Gehirn objektorientiert vor, d.h. es setzt das Gesamtbild aus einzelnen Objekten zusammen. Das Erkennen der Objekte erfolgt durch den Vergleich der visuellen Eingangsdaten mit im Gehirn gespeicherten Erinnerungen (innere Bilder). Ist ein Objekt erkannt, entsteht im Gehirn mit Hilfe der Erfahrungen eine körperliche Vorstellung des Objektes, d.h. man kann sich z.B. auch die im Bild nicht sichtbare Rückseite des Objektes vorstellen. Auch werden alle im Gehirn gespeicherten Eigenschaften dieses Objektes mit der Vorstellung verknüpft. Erkennt das Gehirn ein Objekt z.B. als Haus, so werden u.a. folgende Eigenschaften damit verbunden: Ein Haus besteht aus Steinen, man kann im Haus wohnen usw. Wenn im Bild benachbarte Objekte auf gleiche Weise erkannt wurden, werden diese untereinander in Verbindung gebracht. Stehen mehrere Häuser nebeneinander, so interpretieren wir diese als Siedlung. Die Siedlung bildet jetzt auch ein Objekt, das ebenfalls körperlich ist und auch mit den im Gehirn gespeicherten Eigenschaften (z.B. "besteht aus Häusern") verknüpft wird. Der Mensch kann beliebig zwischen verschiedenen Auflösungen, also verschiedenen Objektgrössen, wechseln. Aus diesen Ausführungen wird deutlich, dass die menschliche Wahrnehmung nicht pixelorientiert sondern objektorientiert abläuft. Die spektralen Werte der einzelnen Pixel reichen zum Erfassen der Umwelt (z.B. einer Siedlung) nicht aus, sondern man braucht auch Kontextinformationen aus benachbarten Objekten oder Unterobjekten, aus denen

<sup>4.</sup> Die Ausführungen in diesem Kapitel beruhen weitgehend auf [7], [18] und [17].



ein Objekt zusammengesetzt ist. Ein farbiger Bildpunkt allein lässt ja noch nicht auf das dazugehörige Objekt schliessen.

Definiens übernimmt mit eCognition das Konzept der objektorientierten Bilderkennung. Für die Bildanalyse werden Objekte gebildet, die bestimmte Eigenschaften und Attribute besitzen. Diese können physikalischer Natur (spektrale, Form- oder Texturinformationen) oder aber auch wissensbasierte Kontextinformationen sein. Ähnlich wie bei der menschlichen Wahrnehmung gibt es verschiedene Auflösungsgrade, mit der die Objekte gebildet werden können. Durch sinnvolles Verbinden der Objekte verschiedener und gleicher Auflösungen entsteht ein hierarchisches Netz, in dem grössere Strukturen in Unterobjekte (Subobjekte) unterteilt werden. Diese Art von Netzwerk basiert auf dem 'fractal net evolution'-Konzept, welches vom wissenschaftlichen Leiter Prof. Dr. Gerd Binnig bei Definiens entwickelt wurde. Um dieses Netzwerk mit den einzelnen Objekten aufzubauen, geht eCogniton in mehreren Schritten vor. Der erste Schritt bildet die Segmentierung ('multiresolution segmentation'), also eine Unterteilung oder Gruppierung des Bildinhaltes in Einzelobjekte aufgrund ihrer spektralen und Formeigenschaften in mehreren Auflösungsstufen. Die anschliessende Klassifikation erfolgt unter Nutzung eines 'nearestneighbour'-Klassifikators oder wissensbasiert durch auf 'fuzzy logic' gestützte Zugehörigkeitsfunktionen. Grundlage ist ein zu entwickelndes semantisches Regelwerk, welches die Klassifikationsbedingungen enthält. Dabei sind die Nachbarschaftsbeziehungen, Relationen zu Subbeziehungsweise Oberobjekten (Superobjekte) und Segmenteigenschaften (wie Formindizes, Nachbarschaftsbeziehungen) neben den Grauwertinformationen als Klassenmerkmale nutzbar. Dadurch wird eine grössere Trennbarkeit der Klassen ermöglicht und eine vollständigere Klassifikation erreicht.

Abbildung 19 zeigt im Überblick den Ablauf einer Klassifikation mit *eCognition* mit der Segmentierung, der 'nearest-neighbour'-Klassifikation, der wissensbasierten Klassifikation und den jeweiligen Informationseingaben.



Abbildung 19: Das Prinzip einer Klassifikation mit eCognition im Überblick



#### 4.1.5. Die Segmentierung

#### 4.1.5.1. Ansatz

Die bisherigen Methoden zur Klassifikation vernachlässigen die Tatsache, dass zwischen benachbarten Pixeln eine signifikante Korrelation besteht, da sie nur die spek-Eigenschaften der einzelnen Pixel benutzen. tralen Besonders in grossmassstäblichen Bildern sind jedoch nicht die Grauwerte der Bildelemente die ausschlaggebenden Informationsträger. Vielmehr liefern die charakteristischen Formen und Regelmässigkeiten sowie die Bezüge von Objekten untereinander die Entscheidung für eine Klassenzugehörigkeit. Die Bildsegmentierung ist ein Verfahren, bei dem das zu klassifizierende Bild in zusammengehörende und homogene Bereiche unterteilt wird, um einerseits die Korrelationen von Pixeln in der örtlichen Nachbarschaft zu berücksichtigen und um andererseits eine Datenreduktion durchzuführen, ohne dass wichtige Informationen verloren gehen [18]. Meyer [14] definiert die Segmentierung wie folgt:

Aufteilung des Bildes in disjunkte, eindeutig identifizierbare Regionen, deren Pixel aufgrund eines statistischen Einheitlichkeitskriteriums gruppiert werden.

Ein Vorteil dieses Verfahrens ist, dass neben den reinen Spektralwerten der Pixel sofort eine Reihe von Parametern zur Beschreibung und damit zur Klassifikation dieser Objekte zur Verfügung stehen: Flächengrösse, Form, Nachbarschaftsbeziehungen, spektrale Mittelwerte und Varianzen und Texturparameter [2].

#### 4.1.5.2. Die Segmentierung mit *eCognition*: 'multiresolution segmentation'

Die Segmentierung wird in *eCognition* 'multiresolution segmentation' genannt. Dabei handelt es sich um eine Segmentierung, die in mehreren Ebenen in verschiedenen Auflösungen stattfindet. In *eCognition* können unter Nutzung von Daten unterschiedlicher Auflösung sowie von Daten unterschiedlicher Herkunft (z.B. zusätzliche GIS-Daten) mehrere solche Segmentierungsebenen angelegt werden [17]. Die Basis der Segmentation ist eine heuristische Optimierungsprozedur, die versucht, die durchschnittliche Heterogenität der Bildobjekte bei einer gegebenen Auflösung über das ganze Bild zu minimieren [7].

Die Heterogenität wird anhand des 'homogeneity criterion' (Homogenitäts-Kriterium) beschrieben, welches in folgende weitere Kriterien aufgeteilt wird [4]:

- Farbkriterium ('colour criterion'): Das Farbkriterium minimiert die Standardabweichung der Spektralwerte eines Bildobjektes.
- **Formkriterium ('shape criterion'):** Das Formkriterium wird nochmals unterteilt in Kompaktheitskriterium und Glättekriterium:
  - Kompaktheitskriterium ('compactness criterion'): In einem Raster ist die ideale kompakte Form eines Objektes ein Quadrat. Das Kompaktheitskriterium minimiert die Abweichung von einer idealen kompakten Form.
  - Glättekriterium ('smoothness criterion'): Das Glättekriterium minimiert das Verhältnis der Kantenlänge eines Objektes zur Kantenlänge des Rechtecks entlang des Rasters, welches das Objekt beinhaltet [6].

Die Segmentierung lässt sich ausserdem durch den Massstabsparameter ('scale factor') steuern, der indirekt die Grösse der Segmente bestimmt [15]. Der 'scale factor' ist ein Mass für die grösste erlaubte Heterogenität eines Bildobjektes, wobei ein kleiner Massstab nur eine kleine Heterogenität zulässt [7]. Für die Segmentierung





müssen die oben genannten Kriterien gewichtet werden. Um die für das jeweilige Bild beste Segmentierung zu erreichen, müssen die Segmentierungsparameter durch wiederholte Versuche herausgefunden werden ('trial-and-error'-Prinzip) [15]. Weitere Ausführungen zur 'multiresolution segmentation' sind in [1] nachzulesen. Für den mathematischen Ansatz und die Durchführung der Segmentierung sei auf den *eCognition* 'User Guide' [4] verwiesen.

#### 4.1.6. Klassifikation mit *eCognition*<sup>5</sup>

Die Klassifikation der segmentierten Objekte erfolgt bei *eCognition* überwacht. Zur Beschreibung der einzelnen Klassen für die überwachte Klassifikation wird die sogenannte 'class hierarchy' verwendet.



Abbildung 20: Beispiel einer 'class hierarchy'

In der 'class hierarchy' können neben den spektralen und geometrischen Eigenschaften auch wissensbasierte Kontextinformationen für die Klassifikation beschrieben werden. Ein weiterer grundlegender Ansatz für die Klassifikation bei *eCognition* ist die Verwendung von 'fuzzy logic'. Beim 'fuzzy-logic'-Ansatz gibt es für bestimmte Merkmalswerte (z.B. Spektralwerte) eines Objektes nicht nur die beiden Aussagen "nein" (0) und "ja" (1), die zu einer Klassenzuordnung führen, sondern die Zuweisung wird durch eine kontinuierliche Funktion mit dem Wertebereich [0...1] ermittelt, wobei 0 ein exaktes Nein und 1 ein exaktes Ja bedeuten. Jeder andere Wert drückt eine Wahrscheinlichkeit der Klassenzugehörigkeit aus. Auf diese Weise können verschiedene Objektmerkmale, wie Spektralwert und Geometrie, aber auch wissensbasierte Kontextinformationen, miteinander verglichen und in Beziehung gebracht werden. Um die einzelnen Merkmalswerte in einen 'fuzzy'-Wert zu übersetzen, benutzt *eCognition* zwei Arten von Klassifikationsalgorithmen: 'membership function' (Zugehörigkeitsfunktion) und 'nearest neighbour'.

4.1.6.1. Klassifikation mit 'membership functions'

Anhand von 'membership functions' oder Zugehörigkeitsfunktionen kann einem Merkmalswert ein Zuweisungswert zugeordnet werden. Mit dieser Methode können neben spektralen und geometrischen Eigenschaften auch Kontextinformationen zur Klassifizierung genutzt werden [4]. Eine Zugehörigkeitsfunktion kann z.B. wie folgt formuliert werden: "Zur Klasse *Lichtungen* gehört alles, was im grünen Kanal einen Grauwert von grösser oder gleich 82 aufweist". Die Spektralwerte kleiner als

<sup>5.</sup> Die Ausführungen in diesem Abschnitt beruhen weitgehend auf [4], [7] und [18].



80 erhalten den Wert 0, über 82 den Wert 1 und dazwischen folgt der Wert der Zuordnungskurve (siehe Abbildung 21).



Abbildung 21: Beispiel einer Zugehörigkeitsfunktion in eCognition

#### 4.1.6.2. 'Nearest-neighbour'-Klassifikation

Der 'nearest-neighbour'-Klassifikator wird auch Minimalentfernung oder in der englischsprachigen Literatur ebenso 'minimum distance' genannt. Hierbei werden die unbekannten Bildelemente den nächstliegenden Trainingspixeln zugeordnet [12] (Abbildung 22).



Abbildung 22: Zuordnung nach der 'nearest-neighbour'-Methode Quelle: [10]

Es müssen Trainingsgebiete definiert werden, da es sich um eine überwachte Klassifikationsmethode handelt. Auch muss darauf geachtet werden, dass die Stichproben einerseits homogen und repräsentativ für die jeweilige Objektklasse sind, und dass andererseits die Streuung innerhalb der Klasse wiedergegeben wird.


### 4.1.6.3. Klassifikationsmerkmale<sup>6</sup>

Um die durch die Segmentierung entstandenen Bildobjekte zu klassieren, können in der 'class hierarchy' sowohl Objektmerkmale als auch klassenbezogene Merkmale implementiert werden. Folgende Merkmale können für eine Klassifikation mit *eCognition* verwendet werden:

Objektmerkmale

- Spektralwerte (Durchschnitt, Standardabweichung, Ratio, Differenz zum Nachbar etc.) der einzelnen Kanäle
- Form (Länge, Fläche, Ausrichtung, Länge der Umrisslinie, etc.) des Bildobjektes oder der Subobjekte (Objekte aus höher aufgelösten Segmentierungsniveaus)
- Textur (Spektral- und Formtextur) des Bildobjektes abgeleitet aus Subobjekten
- Hierarchie-Merkmale (Segmentierungsebene ('Level'), Anzahl der Nachbarund Subobjekte)
- Thematische Merkmale (z.B. aus GIS)

Klassenbezogene Merkmale

- Verhältnis (relative und absolute Grenze, relative Fläche, Distanz, etc.) zu Nachbarobjekten der gleichen Segmentierungsebene
- Verhältnis (relative und absolute Fläche, Anzahl) zu Objekten einer anderen Segmentierungsebene

Alle weiteren Informationen zu den Klassifikationsmerkmalen können in *Definiens* [4] nachgeschlagen werden.

# 4.2. Vorgehen und Resultate

Ziel der Bodenbedeckungsklassierung ist die Extraktion der Landschaftselemente gemäss Teilprojekt A [20], soweit sie digital beschrieben und klassiert werden können. In Teilprojekt A hatte man sich auf den Landschaftselemente-Katalog nach LANA [13], mit Adaptionen für die Hochgebirgssituation und speziell für den Schweizerischen Nationalpark geeinigt. Die Einheitsflächen wurden in sieben Standardkategorien unterteilt zu denen spezielle Zusatzmerkmale definiert wurden (Tabelle 5 auf Seite 38).

Im vorliegenden digitalen Teil B der Untersuchungen wurden für das Testgebiet im Val dal Botsch in einem ersten Schritt die Einheitsflächen nach dem modifizierten LANA-Katalog bestimmt (Kapitel 4.2.4.). Damit sollte ein direkter Vergleich der analogen und digitalen Interpretationen ermöglicht werden. Die digitale Klassifikation beschränkte sich dabei auf die drei Standardmerkmale "Wald", "vegetationsbedeckte Nichtwaldflächen" und "offene natürliche Rohbodenstandorte". Im Untersuchungsgebiet sind an "Gewässern" einzig der Fuornbach und drei kleine Seitenbäche ersichtlich. Diese führten zur Zeit der Datenaufnahme wenig Wasser und können, mangels der Gewässerbreite und infolge der spektralen Mischsignatur "Wasser und Geröll" nicht digital klassiert werden. Sie müssten manuell erfasst werden. Betreffend "Bauten" und "Verkehrsanlagen" sind wenige Gebäude und nur



<sup>6.</sup> Die Ausführungen in diesem Kapitel beruhen weitgehend auf [7].

die Ofenpassstrasse ersichtlich. Auf deren digitale Erfassung wurde verzichtet. "Anthropogen gestörte Gebiete" sind nicht auszumachen.

SNP Code	Standardmerkmal	LANA Code [13]	Zusatzmerkmal	Mindestfläche [ha]
1	Wald	7000	Waldform / -typ Mischung Deckungsgrad Entwicklungsstufe Schlussgrad Struktur Baumarten Totholzart Totholzart Totholzanteil Besondere Ereignisse Bodenbedeckung	0.2
2	Vegetationsbedeckte Nichtwaldflächen	3000 4000 5000 6000	Vegetations-Haupttypen Bodenbedeckung Zwergstraucharten Gebüsch- und Straucharten Moorausprägung	0.2 Moore, Gebüsche: 0.1
3	Offene natürliche Rohbodenstandorte	5000	Standortstyp Bodenbedeckung	0.5
4	Gewässer	2000	Gewässer-Art Struktur Periodizität Vegetation	0.1
5	Bauten / Siedlungen	9000	Gebäudeart / -nutzung	0.1
6	Verkehr / Infrastruktur	9000	Nutzungskategorie / -ausprägung	0.1
7	Anthropogen gestörte Standorte	8000	Nutzungskategorie / -ausprägung	0.1

Tabelle 5:

Systematik der Standard- und Zusatzmerkmale

Quelle: modifiziert nach [13]. In der Arbeit erfasste Merkmale sind hervorgehoben.

Es zeigte sich, dass für die Klassifikation der LANA-Standardmerkmale vorab eine Trennung des Gebietes in Wald- und Nichtwaldanteile notwendig war. Ausgehend von den LANA-Kartiereinheiten wurden sodann diverse Zusatzmerkmale klassiert. Insbesondere sind dies:

- "Waldflächen und Bestandeslücken" (Kapitel 4.2.4.1.)
- "Waldformen" (Kapitel 4.2.5.)
- "Deckungsgrad Wald" und "Schlussgrad Wald" (Kapitel 4.2.6.)
- "Deckungsgrad der Rasengesellschaften" (Kapitel 4.2.7.)

In Kapitel 4.2.8. wird erklärt, warum die Klassifikation des Zusatzmerkmals "Verteilung aufrechte Bergföhre zu Legföhre" mit dem verwendeten Datensatz nicht gelang. Auch auf die Problematik der digitalen Erfassung der "Totholzanteile" wird speziell eingegangen (Kapitel 4.2.9.)





### 4.2.1. Verwendete Daten

In der objektorientierten Klassifikation wurde das Ortholuftbild aus Kapitel 3.2. verwendet. Die Daten liegen digital mit einer Auflösung von einem Meter in drei Farbebenen, entsprechend dem Falschfarbenfilm, vor. (siehe Abbildung 10 auf Seite 22). Zur Demonstration der Erkennbarkeit von Totholz wurden auch Ausschnitte des Ortholuftbildes mit 20 cm Auflösung verwendet.

Die Informationen zur Topographie konnten dem digitalen Geländemodell des Schweizerischen Nationalparks mit 10 m Bodenauflösung entnommen werden (siehe Kapitel 2.2.). Speziell wurden die "Höhe über Meer" und die abgeleiteten Parameter "Exposition" und "Hangneigung" in den Klassifikationsprozess eingebunden. An dieser Stelle ist speziell zu erwähnen, dass das Geländemodell ein Modell des Bodens und nicht der Vegetationsoberfläche (Kronendach) repräsentiert.

Eine überwachte Klassifikation bedeutet, dass der Interpret für jede zu klassierende Bodenbedeckung repräsentative Stichproben definieren muss. Für alle Objektklassen wurden die Stichproben in den Bilddaten direkt gesetzt. Zur Definition der Stichproben wurde auch auf die analoge Klassifikation zurückgegriffen und speziell mittels dem Wissen des Interpreten homogene Regionen definiert. Die Verifikation der Stichproben erfolgte bei einer Feldbegehung im Untersuchungsgebiet. Zusätzlich stand eine digitale Vegetationskartierung des SNP mit Einheiten nach Zoller aus dem Jahr 1992 zur Verfügung. Sie wurde nur zur grossräumigen und sehr groben Abschätzung vegetationsbedeckter Gebiete analog verwendet.

# 4.2.2. Arbeitsumgebung

Die digitale Klassifikation wurde mit der Software *eCognition* Version 2.1 durchgeführt. Die Software läuft exklusiv in einer *Windows*-Umgebung. Der verwendete Rechner mit 1 Gigabyte RAM und einem 1 GHz Prozessor erwies sich als minimalste Ausstattung für die zu verarbeitende Datenmenge. Besonders RAM muss genügend verfügbar sein. Zur Visualisierung haben sich ein 22" CRT oder die Kombination zweier 18" TFT-Monitore bewährt.

Für die Darstellung der Ergebnisse zusammen mit der topographischen Karteninformation und die thematische Kartenherstellung (siehe A.1 bis A.8) wurden die Klassierungen in *ArcView* übernommen und bearbeitet.

# 4.2.3. Segmentierungsschritt

Zuerst wurden die Daten (digitalisiertes Luftbild, Geländemodell und dessen Derivate) eingelesen und auf verschiedenen Skalierungsstufen in homogene Objekte segmentiert. Die Segmentierung in *eCognition* ist mit einer 'blackbox' zu vergleichen. Dem Benutzer stehen neben dem Skalierungsparameter 'scale' nur die beiden direkt linear gekoppelten Kriterien 'homogeneity' und 'compactness' zur Verfügung. Der Benutzer wählt den Skalierungsfaktor entsprechend der zu detektierenden Objektgrössen.

Für dieses Projekt wurden primär drei Skalierungsstufen gewählt (Tabelle 6 auf Seite 40). In der Segmentierungsebene eins wurden Waldflächen und vegetationslose oder vegetationsbedeckte Nichtwaldflächen als Objekte ausgeschieden. Die mittlere Objektfläche beträgt hier ca. 5350 m<sup>2</sup>. Mit dem Kriterium der 'compactness' können die Objektrandeigenschaften gesteuert und mit der Homogenität der mittlere Objektkontrast zu den umgebenden Objekten angepasst werden. Die opti-



male Einstellung dieser zwei Parameter muss der Benutzer durch iteratives Austesten selber finden. Versuche haben gezeigt, dass Parameter auf vergleichbare Datensätze, mit gleichen Objekttypen, in vielen Fällen übertragen werden können.

Die Segmentierung wurde auf zwei weiteren Auflösungsniveaus wiederholt, wobei in der Ebene zwei die Objekte einzelne Baumgruppen oder Bestandeslücken und in Ebene drei Einzelbäume repräsentieren. Die Zusatzebene zwischen Ebene zwei und drei diente vor allem der Generierung von Struktur- und Texturparametern für Objekte der Ebene zwei. Der resultierende Datensatz mit drei, bzw. vier Objektebenen, wurde im nächsten Schritt klassiert (siehe Kapitel 4.1.6.).

Ebene	<i>Skalierungsparameter</i> (eCognition)	Objekt	Mittlere Objektfläche in [m2]	Generierte Objekte (Ausschnitt der Segmentierungsebenen)
1	Scale: 4 Homogeneity: 0.3 Compactness: 0.5	Waldfläche Nichtwaldfläche	5365	
2	Scale: 15 Homogeneity: 0.3 Compactness: 0.5	Baumgruppe Bestandeslücke	128	
	Scale: 75 Homogeneity: 0.3 Compactness: 0.5	Zusa	tzlevel für statistische Par	ameter auf Objektlevel 2
3	Scale: 100 Homogeneity: 0.3 Compactness: 0.5	ein bis zwei Einzelbäume	9	

 Tabelle 6:
 Übersicht der Segmentierungsebenen



### 4.2.3.1. Stabilität der Segmentierung

In der verwendeten Version 2.1 von *eCognition* werden für die Segmentierung am Bildrand Startpunkte ('seedpoints') nach dem Zufallsprinzip ohne eine Möglichkeit der Benutzerinteraktion gesetzt. Ausgehend von diesen Punkten erfolgt die Unterteilung des Bildes in homogene Objekte durch ein 'region growing'. Wird das gleiche Bild mit den identischen Parametern mehrmals segmentiert, so weichen die erzielten Objekte in Form und Grösse, besonders im Randbereich, immer leicht voneinander ab. Ein Test mit einem kleinen Bildausschnitt, der mit identischen Parametern mehrmals segmentiert, Tabelle 7).

	Anzahl Objekte	Mittlere Objektfläche in [m <sup>2</sup> ]
1. Segmentierung	79464	221.02
2. Segmentierung	79810	221.99
3. Segmentierung	79578	221.58
4. Segmentierung	79483	221.69

Tabelle 7:
 Mehrmalige Segmentierung des identischen Ausschnittes mit gleichbleibenden Parametern

Diese Instabilität wird zu einem grossen Hindernis, wenn ein Gebiet mehrmalig bearbeitet werden soll. Besonders in einem multitemporalen Ansatz kommt dies zum Tragen. Grosse Gebiete wie der SNP müssen in Teilgebieten (Teilprojekte) bearbeitet werden. Dann wirkt sich die Segmentierungsinstabilität in den Übergangsbereichen negativ aus. Version 2.1 von *eCognition* gibt zusätzlich dem Benutzer keine Gelegenheit, einzelne Objekte manuell zu editieren oder zu unterteilen. Insbesondere bei grossräumigen, homogenen Bodenbedeckungstypen ist dies von Nachteil.

*Definiens* veröffentlichte Ende 2002 die Version 3.0 von *eCognition*, welche die genannten Unzulänglichkeiten nun behebt [5]. Die Startpunkte für die Segmentierung können nun übertragen werden, die Segmentierung bleibt absolut stabil und Objekte sind editierbar. Damit ist die gesamthafte saubere Klassierung des SNP nun möglich.

# 4.2.4. LANA - Kartiereinheiten

Für die digitale Klassifikation ist es von grossem Vorteil, wenn im Untersuchungsgebiet zuerst eine Trennung in Wald- und Nichtwaldgebiete erfolgt. Auf der Basis der feinsten Segmentierungsebene 'drei' (Tabelle 7 auf Seite 41) wurde anhand von Trainingsgebieten und mittels dem 'nearest-neighbour'-Ansatz die Klassifikation durchgeführt. Abbildung 23 auf Seite 42 zeigt einen Ausschnitt der erreichten Abgrenzung. Weil in Zonen mit extremem Schatten keine spektral variierende oder relevante Information vorliegt, traten vereinzelte Fehler auf, die durch den Einbezug der bestehenden Vegetationskarte (Kapitel 4.2.1.) auch nicht eliminiert werden konnten. Die geometrischen Eigenschaften und der Massstab der Karte waren ungenügend.





Luftbild

#### objektorientierte Klassifizierung

analoge Interpretation

# Abbildung 23: Wald- / Nichtwaldkartierung

Die Verwendung der höchsten Segmentierungsebene drei mit den feinsten Objektgrössen für die Waldabgrenzung hat den Vorteil, dass einzelne Bäume, kleinste Baumgruppen und sogar Büsche erfasst werden. Die mittlere Objektgrösse von 9 m<sup>2</sup> erlaubt es, die Mindestflächengrösse nach LANA (Tabelle 5 auf Seite 38) von 0.2 ha für den Wald problemlos zu erreichen. Digital können die Objekte nachträglich zusammengefasst werden und es bedeutet generell keinen Mehraufwand solch kleine Objekte auszuweisen. In einer analogen Vorgehensweise wäre dies aus Sicht des Interpreten und der Ökonomie nicht vertretbar.

Die Waldabgrenzung wurde zusammen mit dem digitalen Höhenmodell im folgenden Schritt verwendet, um die eigentlichen LANA Standardmerkmale zu klassieren. Mittels überwachten Stichproben wurden neun Arbeitsklassen gemäss Tabelle 8 auf Seite 43 gebildet. "Grasflächen" und "Rohbodenstandorte" mussten wegen ihrer spektralen Eigenschaften in verschiedene Arbeitsklassen aufgeteilt werden. Es bestanden aber auch Überlappungen zwischen den Klassen "Bestandeslücken" und "Grasflächen". Die Grasflächenklassen wurden weiter in Subklassen unterteilt, je nachdem ob sie sich in Waldgebieten oder auf freiem Feld befanden.

Die Vorgehensweise in *eCognition* erlaubt es, verschieden klassierte Objekte nachträglich wieder in eine Hauptklasse zusammenzufassen. So bilden beispielsweise die Klassen 1,2 und die Subklassen 4b, 5b, 6b, und 9b die gesamte Waldfläche.





Klassen-Nr.	Klassen	Subklassen	Klassifikator	Hilfsvariable	
1	Kronenbereich		NN ('nearest neighbour')	DHM (< 2320 m ü.M.)	
2	Kronen + Schatten		NN	DHM (< 2320 m ü.M.)	
3	Boden+ Vegetation_Bestandeslücken		NN	Wald-Nichtwald (E3)	
4	Grasflächen1	a- Grasland_Nichtwald1		Wald-Nichtwald (E3)	
	Grushuenen	b- Bestandeslücken_G1	NN	Wald-Thentwald (E5)	
5	Grasflächen2	a- Grasland_Nichtwald2		Wald-Nichtwald (E3)	
		b- Bestandeslücken_G2	NN		
6	Grasflächen3	a- Grasland_Nichtwald3		Wald-Nichtwald (E3)	
		b- Bestandeslücken_G3	NN		
7	Rohboden1		NN	Wald-Nichtwald (E3)	
8	Pakhadan?	a- Rohboden2_Nichtwald		Wold Nichtwold (E2)	
0	Kohoodenz	b- Rohboden2_Bestandeslücken	NN	Wald-Inclitivald (ES)	
0	Schatten	a- Wald_unter_Schatten		Wald-Nichtwald (E3)	
,	Schauch	b- Nichtwald_unter_Schatten	NN	DHM, Hangneigung	
10	Background		'Membership Function'		

Tabelle 8: Klassenbildung

In Abbildung 24 ist ein Ausschnitt der Kartierung nach LANA-Einheiten, im A.1, "Kartiereinheit gemäss LANA (1995)," auf Seite 72 ist das gesamte Untersuchungsgebiet dargestellt. Die Verifizierung der Klassifikation ist Kapitel 5. zu entnehmen.







Abbildung 24: Ausschnitt der Kartiereinheiten nach LANA



Dokument:	projects/LB-SNP_Pilot/doc/final_report
Version:	1.0
Datum:	29. August 2003
Seite:	44 von 101

#### 4.2.4.1. Waldfläche und Bestandeslücken

Die Klassenbildung wie sie für die LANA-Kartierung vorgenommen wurde (Tabelle 8 auf Seite 43), erlaubt es, die Bestandeslücken und die Waldfläche einfach und schnell zu kartieren. Bestandeslücken mit unterschiedlicher Bodenbedeckung können automatisch kartiert werden. Bei der visuellen Interpretation wäre diese Kartierung sehr kostenintensiv wenn nicht sogar unmöglich. Wie Abbildung 25 und A.2, "Waldfläche und Bestandeslückenkartierung," auf Seite 73 zeigen, wurde in den Bestandeslücken zudem nach Vegetationsbedeckung unterschieden.



Abbildung 25: Ausschnitt der Waldflächen und Bestandeslücken

4.2.4.2.

#### Optimierungsmöglichkeiten

Die objektorientierte Klassifikation der LANA-Einheiten sowie der Bestandeslükkenkartierung kann von einem Interpreten mit guten Kenntnissen des Programmes *eCognition* in einem bis zwei Arbeitstagen erfolgen. Der Arbeitsaufwand an sich ist unabhängig von der auszuwertenden Fläche, sofern sie in einem Projekt verarbeitet werden kann. Limitierender Faktor ist die Computerleistung (Kapitel 4.2.2.).

In starken Schattenbereichen wie an der Waldgrenze und an schattigen Berghängen erweist sich die Objektextraktion als sehr schwierig, wenn nicht sogar unmöglich. Bei der Datenaufnahme (Befliegung) ist einem optimalen Sonnenstand (Tageszeit, Jahreszeit) unbedingt Rechnung zu tragen. Die Flächenschätzung der Bestandeslükken könnten z.T. mittels Einsatz von Nachbarschaftsbeziehungen (Minimierung vom Baumschatten am Lückenrand) verbessert werden. Wenn vor der digitalen Klassierung eine grobe analoge Delineation der Waldgrenze erfolgt, so kann diese Information in einer markanten Verbesserung der Waldabgrenzung resultieren. Ein kombinierter Analog-Digital-Ansatz ist daher wünschenswert.

Eine weitere Verbesserung ist sicherlich mit dem Einbezug eines höchstauflösenden Boden- und Oberflächenmodells zu erreichen. Solche Modelle werden heute durch eine Befliegung mittels eines 'airborne Laserscanners' gleichzeitig im 'first-pulse' und 'last-pulse' Verfahren erreicht. Mit diesen Zusatzinformationen könnten die Objekte im Schattenbereich präziser differenziert werden.



### 4.2.5. Waldformen

Unter den Waldformen versteht man die vertikale Struktur eines Bestandes. Dabei wird unterschieden zwischen Hochwald, Gebüschwald und den Mischformen. Für die objektorientierte Klassifikation der Waldform wurde ein neues *eCognition* Projekt aufgesetzt mit den gleichen Segmentierungsstufen wie zuvor (Tabelle 7 auf Seite 41). Zusätzlich wurde die vierte Segmentierungsstufe zwischen Level zwei und drei verwendet. Dieser Level erlaubte die Berechnung von statistischen 'membership'-Funktionen mittels derer die Objekte auf Ebene zwei klassiert werden konnten: Ein Grauwerteindex und ein Texturmerkmal.





Die strukturelle, kleinflächig abwechselnde Heterogenität des Waldgebietes konnte automatisch in Klassen diskriminiert werden (Abbildung 26, sowie A.3, "Waldformen," auf Seite 74 und A.4, "Waldformen (vertikale Struktur)," auf Seite 75), obwohl keine eigentliche Information über die vertikale Struktur (Baumhöhen) miteinbezogen und die Klassifikation nicht in einem Stereomodell durchgeführt wurde. Solange die Baumhöheninformation im objektorientierten Klassifizierungsverfahren nicht einbezogen wird, ist die Diskriminierung zwischen Hoch-, Gebüschwald und gemischten Beständen durch eine analoge oder digitale, dreidimensionale Auswertung als zuverlässiger zu betrachten. Der Einbezug der Baumhöhenangaben (z.B. Laserscannerdaten) im objektorientierten Klassifizierungsprozess könnte einen Beitrag zu flächendeckenden Aussagen über die innere Waldstruktur leisten, speziell in modernen Ansätzen zur Beschreibung ungleichförmiger, strukturreicher Wälder. Sie basieren auf der Analyse von Nachbarschaftsverteilungen der Bäume (z.B. Entfernung der drei nächsten Nachbarn eines Nullbaumes) oder auf dreidimensionalen Modellen (z.B. 'Structural Complexity Index'). Laserscannerdaten könnten auch einen Beitrag zur Minimierung der Schatten innerhalb eines Bestandes liefern.



#### 4.2.6. Deckungsgrad Wald und Schlussgrad Wald

Der Deckungsgrad kann kleinräumig automatisch in Klassen getrennt werden (Abbildung 27 und A.6, "Deckungsgrad (gruppierte Klassen)," auf Seite 77). Wie bei den Waldformen wurde der Segmentierungslevel zwischen Level zwei und drei verwendet. Ein Parameter ('arithmetic feature': Summe der relativen Fläche der Waldklassen der Subobjektebene) wurde berechnet, um die Deckungsgradklassen zu diskriminieren. Die Deckungsgradklassen in 10% Aufteilung, wie sie im analogen Teilprojekt A [20] gemacht wurde, ist aber stark idealisiert, generalisiert. Um den Vergleich zu erlauben, wurden hier die 10% Klassen ausgeschieden, aber auch eine Gruppierung in nur vier Deckungsgradstufen vorgenommen.



Abbildung 27: Ausschnitt Deckungsgrad Wald

Die Schatten im Bodenbereich können bei der Zuweisung zu unterschiedlichen Deckungsgradklassen sehr störend wirken. Der Deckungsgrad wird oft überschätzt. Durch Nachbarschaftsbeziehungen könnten die Schatten am Waldrand oder in grösseren Bestandeslücken minimiert werden. Dadurch würde eine präzisere Deckungsgradschätzung erreicht werden.

Wiederum mit Laserscannerdaten könnten Schatten innerhalb des Bestandes und Hängen minimiert und die Baumkronenbreite von Einzelbäumen präziser bestimmt werden. Ausserdem wäre damit möglich, Informationen über die Mittel- und Unterschichtbedeckung zu gewinnen. Die Deckungsgradklassen könnten in direkter Form geschätzt werden.

Der Schlussgrad Wald kann ebenfalls kleinräumig anhand von Texturmerkmalen und Klassenbeziehungen zu Subobjektebenen automatisch erfasst werden (Abbildung 28 auf Seite 47 und A.7, "Schlussgrad," auf Seite 78). Da die Schatten ein bestimmtes Muster bei ähnlicher Überschirmungsform aufweisen, kann der Schlussgrad herangezogen werden. Mit Einbezug von Laserscannerdaten könnten auch Schlussgradklassen präziser bestimmt werden.







Abbildung 28: Ausschnitt Schlussgrad Wald

Deckungsgrad der Rasengesellschaften

# 4.2.7.

# Die erstellte Karte unterscheidet drei Deckungsgradstufen der Rasengesellschaften (< 33%, 33%-66%, > 66%). Es scheint jedoch sinnvoller, Biomasse statt Deckungsgrad der Rasengesellschaften zu kartieren. Die Grasflächen unterscheiden sich mehr

nach ihrem Vorrat und nicht nach ihrer räumlichen Konstellation.



Abbildung 29: Ausschnitt Deckungsgrad der Rasengesellschaften

4.2.8.

# Verteilung aufrechte Bergföhre zu Legföhre

Die Verteilung der aufrechten Bergföhre, beziehungsweise der Legföhre zu kartieren gelingt mit dem vorhandenen Datensatz und *eCognition* nicht. Die zwei Baumtypen unterscheiden sich im Falschfarbenluftbild spektral nicht. Auch konnten keine differenzierenden Texturmerkmale oder Strukturmerkmale erkannt werden. Einzig die Wuchshöhenunterschiede könnten eine erfolgreiche Klassierung ermöglichen.



Vielleicht würde der Einbezug eines genügend genauen Boden- und Oberflächenmodells die Klassifikation ermöglichen.

#### 4.2.9. Totholzanteile

Totholz zu erkennen und zu kartieren ist für den SNP wichtig und für ein Monitoring unerlässlich. Auf der Basis des digitalen Luftbildes mit 1 m Auflösung ist dies nicht möglich. Verwendet man das digitale Luftbild mit 20 cm Auflösung, ist liegendes Totholz in lichten Beständen zu erkennen (Abbildung 30).



1m Auflösung

20 cm Auflösung

# Abbildung 30: Totholzerkennung: Vergleich 1 m und 20 cm Auflösung

In einem kleinen Ausschnitt mit 20 cm Auflösung wurden zur Demonstration der Klassierbarkeit Stichproben gesetzt und mittels eines NN-Klassifikators eine Kartierung des Totholzes durchgeführt (Abbildung 31 auf Seite 49). Liegendes Totholz, welches nicht beschattet oder mit Kronen bedeckt ist, kann gut kartiert werden (gelb). In den übrigen Fällen sind ganze Baumstämme nicht zu kartieren (grün) oder einzelne Objekte gar nicht zu identifizieren (weiss). Totholzkartierung mit 20 cm Luftbilddaten stellt hohe Anforderungen an die Computerleistung und kann mit diesem Klassifikationsansatz nur bedingt kartiert werden. Eine analoge Interpretation, vielleicht sogar basierend auf einer digitalen Vorklassifikation, ist anzustreben. Inwieweit eine bessere spektrale Auflösung (hyperspektrale Sensoren) und/oder der Einbezug von genauer Höheninformation (Boden-/Oberflächenmodell) eine Verbesserung bewirken kann, ist momentan Gegenstand anderer Untersuchungen im Nationalpark.





20 cm Auflösung



# 4.3. Schlussfolgerungen

An dieser Stelle sollen nicht endgültige Schlussfolgerungen zur Kartierung erfolgen. Erst die Analyse der terrestrischen Verifikation (Kapitel 5.) zeigt endgültig ob diese Klassifikationsmethode geeignet ist. Wie die Erfahrungen im Klassifikationsprozess aber zeigten, verspricht der vorgestellte digitale und objektorientierte Bildanalyse-Ansatz einige der Engpässe der traditionellen Bildinterpretation zu beseitigen. Auch wenn das objektorientierte Verfahren eine monoskopische Betrachtungsweise des digitalen Luftbildes darstellt, können einige wichtige Forstparameter hergeleitet werden. Die Kartierung der Waldstrukturparameter, welche vor allem durch die Baumhöhe bestimmt werden (z.B. Waldformen, vertikale Struktur), sollten jedoch mit Vorsicht betrachtet und unbedingt im Gelände verifiziert werden.

Falschfarben-Luftbilder mit 1 m Auflösung sind für die im Rahmen dieser Arbeit erstellten Karten geeignet. Durch eine halbautomatische Klassifizierung der digitalen Luftbilder wird neben der verbesserten Objektivität und Repetierbarkeit eine feinere, präzisere Objektextraktion mit Kosteneinsparungen ermöglicht.

Sofern für die Klassifikation keine Zusatzinformationen auf Baumebene, wie differenziert aufgenommene Waldflächen und/oder Boden- und Oberflächenmodelle aus Laserscannerdaten verfügbar sind, ist für eine umfassende Waldkartierung eine kombinierte digitale und analoge Auswertemethode vorzuziehen. Zwischen der analogen photogrammetrischen Auswertung und dem digitalen objektorientierten Verfahren müssen Daten und Informationen in einem iterativen Prozess ausgetauscht werden können. Dies könnten Stratifizierungen, Verifizierungsfeedbacks, Vorklassifikationen und Nachklassifikationen sein. So würde eine vorgängige analoge Inter-



loge Interpretation der Waldfläche, die nur sehr schematisch erfolgen müsste, die digitale Klassifikation sehr erleichtern. Höhenstrukturen, wie die Verteilung der Legföhre und der aufrechten Bergföhre, könnten in einer analogen Interpretation, nach der digitalen Segmentierung und Vorklassifikation, auf Basis der Objekte erfasst werden.

Die automatisierte Segmentierung ist mit *eCognition* Version 2.0 nicht, mit der neuen Version 3.0 aber absolut reproduzierbar. Somit können die segmentierten Objekte direkt als Beobachtungsflächen ausgewählt und in einem längerfristigen Monitoring auch beobachtet werden. Insbesondere wurde dies möglich, weil segmentierte Ebenen, die aus früheren Projekten stammen, in eine neue Auswertung übertragen werden können.

Die objektorientierte Klassifikation bietet speziell Lösungen für die Probleme der Bildfusion, Datenfusion und Integration von Expertenwissen. Weitere Forschungsund Überprüfungsarbeit ist dennoch erforderlich, um diese Art von Bildanalyse in der Praxis als allgemein anerkannt zu etablieren. Für die Auswertung des SNP ist das Klassifikationsvorgehen in weiteren Gebieten zu testen, in denen zusätzliche LANA-Klassen vorkommen und die Beleuchtungssituation und die Topographie eine andere Ausprägung haben. Übergangsprobleme zwischen einzelnen Auswertegebieten (Projekte in *eCognition*) sind auf Objektebene zu erwarten. Die Übertragbarkeit der Startpunkte für die Segmentierung von einem Projekt auf das nächste sollte mit Version 3.0 gewährleistet sein, bedarf aber einer Überprüfung.



# 5. Genauigkeitsanalyse der automatischen Klassifikation

# 5.1. Einleitung

Das Resultat der automatischen Klassifikation wurde mit dem Ergebnis der manuellen Interpretation (Teilprojekt A) verglichen. Der Vergleich basiert auf einer statistischen Gegenüberstellung der beiden Interpretationsergebnisse und einer terrestrischen Kontrolle auf ausgewählten Flächen.

# 5.2. Methodisches Vorgehen

# 5.2.1. Statistischer Vergleich

Für die einzelnen thematischen Aspekte (LANA-Kartiereinheiten, Waldformen, Walddeckungsgrad, Waldschlussgrad und Rasendeckungsgrad) wurde einerseits das relative Auftreten einer Klasse sowie die Anzahl übereinstimmender Pixel ermittelt. Diese wurden mittels einer Übereinstimmungsmatrix (vgl. Tabelle 9 auf Seite 51) errechnet, aus der zusätzlich die Gesamtgenauigkeit und der Kappa-Koeffizient berechnet wurden.

			eCognition Klassifikation			
	Klasse	1	2		i	übereinstimmende Pixel Gesamtzahl der Pixel in dieser Klasse (Vergl. mit manueller Klassifikation)
1	1	X <sub>11</sub>	X <sub>12</sub>		X <sub>li</sub>	$\frac{x_{11}}{\sum_{a=1}^{n} x_{1a}}$
elle Interpretation	2	X <sub>21</sub>	X <sub>22</sub>		X <sub>2i</sub>	$\frac{x_{22}}{\sum_{a=1}^{n} x_{2a}}$
nanı	•••		•••			•••
	i	X <sub>il</sub>	X <sub>i2</sub>		X <sub>ii</sub>	$\frac{x_{ii}}{\sum\limits_{a=1}^{n} x_{ia}}$
übereinstimmende Pixel Gesamtzahl der Pixel in dieser Klasse (Vergl. mit <i>eCognition</i> Klassifikation)		$\frac{x_{11}}{\sum\limits_{a=1}^{n} x_{a1}}$	$\frac{x_{22}}{\sum\limits_{a=1}^{n} x_{a2}}$		$\frac{x_{ii}}{\sum\limits_{a=1}^{n} x_{ai}}$	n=Anzahl Klassen N=Gesamtpixelzahl

Tabelle 9:Übereinstimmungsmatrix

Die Übereinstimmungsmatrix stellt die Pixel in den einzelnen Klassen dar. Auf der horizontalen Achse ist dabei die Klassifikation mit *eCognition* und auf der vertika-





len Achse die manuelle Interpretation aufgetragen. Die übereinstimmenden Pixel werden in der Übereinstimmungsmatrix durch alle Elemente der Hauptdiagonalen (fett gedruckt) dargestellt. Die Gesamtgenauigkeit bzw. der Kappa-Koeffizient lassen sich wie folgt berechnen:

#### Gesamtgenauigkeit

Die Gesamtgenauigkeit ist das Verhältnis der übereinstimmenden Pixel (Hauptdiagonale) zur Gesamtzahl der Pixel.

$$A_0 = \frac{\sum_{a=1}^n x_{aa}}{N}$$

### Kappa-Koeffizient

Um die sogenannte Zufallsübereinstimmung von der Gesamtgenauigkeit zu entfernen, wird der Kappa-Koeffizient berechnet. Der höchste Wert des Kappa-Koeffizientes ist 1 und entspricht dann einer 100-prozentigen Übereinstimmung.

Kappa-Koeffizient = 
$$\frac{A_0 - Q}{1 - Q}$$

Wobei:

$$Q = \frac{\sum_{a=1}^{n} x_{ai} \times x_{ai}}{N^2}$$

die Zufallsübereinstimmung ist.

Für die Parameter "Walddeckungsgrad", "Waldschlussgrad" sowie "Rasendekkungsgrad" lag die Klassenunterteilung der manuellen Interpretation jeweils in 10% Intervallen vor und stimmte nicht mit der Einteilung der automatischen Klassifikation überein. Deshalb wurden die Klassen der manuellen Interpretation entsprechend zusammengefasst.

# 5.2.2. Terrestrische Kontrolle

Verschiedene Kontrollflächen wurden direkt im Nationalpark untersucht, welche auf Basis einer vorgängig hergestellten Differenzkarte ausgeschieden wurden. Dabei wurden Flächen berücksichtigt, die bei beiden Interpretationsverfahren zu offensichtlich unterschiedlichen Ergebnissen führten. Abbildung 32 auf Seite 53 gibt einen Überblick über die ausgeschiedenen Kontrollflächen.





Abbildung 32: Kontrollflächen für die terrestrische Verifikation © Bundesamt für Landestopographie

# 5.3. Resultate

In diesem Abschnitt werden die Ergebnisse des statistischen Vergleichs und der terrestrischen Kontrolle für die untersuchten thematischen Aspekte (LANA-Kartiereinheiten, Waldformen, Walddeckungsgrad, Waldschlussgrad, Rasendeckungsgrad) dargestellt und anhand von Fallbeispielen erläutert. Eine Zusammenfassung der Resultate folgt im anschliessenden Kapitel.

# 5.3.1. LANA-Kartiereinheiten

In Tabelle 10 auf Seite 53 sind die relativen Flächenanteile der LANA-Kartiereinheiten aufgeführt. Der Anteil der Klassen bewegt sich bei beiden Verfahren in einem ähnlichen Bereich, was bereits auf eine gute Übereinstimmung hindeutet. Verglichen mit der manuellen Interpretation ist der Anteil Wiesen bei der Klassifikation mit *eCognition* auf Kosten der Klassen "Rohboden" und "Wald" leicht tiefer.

	Rohboden	Wiesen	Wald
eCognition Klassifikation [%]	17.2	18.4	64.4
manuelle Interpretation [%]	15.1	23.2	61.7

Tabelle 10:Relative Häufigkeitsverteilung der LANA-Kartiereinheiten für die Klassi-<br/>fikation mit eCognition und die manuelle Interpretation



Die Übereinstimmung bezogen auf die Waldfläche liegt deutlich über 90%. Für die Klassen "Rohboden" und "Wiesen" beträgt sie knapp 75%.

		eCo			
	Klasse	Rohboden	Wiesen	Wald	Übereinstimmung
telle pretation	Rohboden	460810	37775	107948	76.0 %
	Wiesen	177634	679802	76016	72.8 %
manı Inter	Wald	53742	22124	2407223	96.9 %
	Übereinstimmung	66.6 %	91.9 %	92.9 %	

Tabelle 11: Übereinstimmungsmatrix für die LANA-Kartiereinheiten

Die Gesamtgenauigkeit und der Kappa-Koeffizient betragen 88% bzw. 0.78. Die statistischen Vergleiche und Genauigkeitsmasse zeigen, dass die Übereinstimmungen zwischen manueller Interpretation und automatischer Klassifikation gross sind. Unterschiede treten in geringem Ausmass bei den Klassen "Rohboden" und "Wiesen" auf.

Anhand der folgenden Fallbeispiele werden die Unterschiede der beiden Interpretationsverfahren illustriert und auf Probleme und Einschränkungen hingewiesen.



# Fallbeispiel 1

Abbildung 33 auf Seite 55 zeigt einen aufgelösten Waldbestand, wie er typischerweise an der oberen Waldgrenze vorkommt. Gut zu erkennen ist, dass bei der manuellen Interpretation die kleinflächige rottenartige Struktur und vereinzelte Legföhren nicht erfasst werden. Bei der Klassifikation mit *eCognition* hingegen bleiben die mosaikartige Struktur erhalten. Im geschlossenen Hochwald mit klar abzugrenzenden Waldrändern werden mit beiden Verfahren gute Ergebnisse erzielt. Die Klassifikation mit *eCognition* zeichnet sich durch einen hohen Detailierungsgrad auf, wogegen mit der manuellen Interpretation eher eine Generalisierung erzielt wird.

Wald Rohbodenstandorte Wiesen







manuelle Interpretation

Luftbild (CIR-Orthophoto)

eCognition Klassifikation



Übersicht (Blickrichtung von oben rechts nach links unten)

Abbildung 33: Kontrollfläche 11 ("LANA-Kartiereinheiten")



# Fallbeispiel 2

In Abbildung 34 auf Seite 56 ist zu erkennen, dass die Wiesenfläche nicht geschlossen ist, sondern von einem Mosaik von Rohbodenflächen durchzogen wird. Bei der manuellen Interpretation verschwindet diese kleinflächige Struktur gänzlich, wogegen bei der Klassifikation mit *eCognition* die mosaikartige Struktur wiedergegeben wird. Zu beachten gilt es, dass der Rohbodenanteil an den stark überstrahlten Hängen generell überschätzt wird.





Übersicht (Blickrichtung von unten nach oben)

Abbildung 34: Kontrollfläche 16 ("LANA-Kartiereinheiten")



# Fallbeispiele 3 und 4

Probleme treten bei der Klassifikation vor allem in beschatteten Gebieten auf, wie das Abbildung 35 auf Seite 57 und Abbildung 36 auf Seite 57 deutlich zeigen. Eine durch die terrestrische Kontrolle verifizierte Bestandeslücke wurde durch die manuelle Interpretation korrekt erkannt (Abbildung 35 auf Seite 57). Bei der Klassifikation mit *eCognition* reicht die spektrale Information des Schattengebietes nicht mehr aus, um eine korrekte Klassifikation zu gewährleisten.

Wald Rohbodenstandorte Wiesen







manuelle Interpretation

Luftbild (CIR-Orthophoto)

eCognition Klassifikation

# Abbildung 35: Kontrollfläche 10 ("LANA-Kartiereinheiten")

Ein ähnliches Beispiel ist in Abbildung 36 auf Seite 57 illustriert. Der Eigenschatten des Waldbestandes reicht in die angrenzenden Ebenen hinein. Auch hier liefert Textur und spektrale Eigenschaften zuwenig Informationen, um eine korrekte Abgrenzung des Waldbestandes bei der automatischen Klassifikation durchzuführen. Bei der manuellen Interpretation werden schattige Gebiete genauer klassifiziert.

Wald Rohbodenstandorte Wiesen









eCognition Klassifikation



Übersicht (Blickrichtung von links oben nach rechts unten)

Abbildung 36: Kontrollfläche 22 ("LANA-Kartiereinheiten")



#### 5.3.2. Waldformen

Beide Klassifikationen weisen einen etwa gleich hohen Anteil an Hochwald von knapp 80% aus. Bei der Klassifikation mit *eCognition* wird im Vergleich zur manuellen Interpretation allerdings vermehrt Mischwald ausgeschieden (11.3% zu 6.1%). Dem gegenüber ist bei der manuellen Interpretation der Anteil an Gebüschwald höher.

	Hochwald	Gebüschwald	Gemischt
eCognition Klassifikation [%]	79.1	9.6	11.3
manuelle Interpretation [%]	79.8	14.1	6.1

Tabelle 12:Relative Häufigkeitsverteilung der Waldformen für die Klassifikation mit<br/>eCognition und die manuelle Interpretation

Die Übereinstimmungsmatrix (Tabelle 13 auf Seite 58) zeigt, dass der Hochwald von beiden Interpretationsverfahren mit einer hohen Übereinstimmung erkannt wurde. Die Unterschiede für die Klassen "Gebüschwald" und "gemischt" sind etwa gleich zu beurteilen.

		eCo			
	Klasse	Hochwald	Übereinstimmung		
tion	Hochwald	1729706	94990	117396	89.1 %
uelle preta	Gebüschwald	155965	106534	81061	31.0 %
manı Inter	gemischt	39117	31346	77385	52.3 %
	Übereinstimmung	89.9 %	45.7 %	28.1 %	

Tabelle 13:Übereinstimmungsmatrix für die Waldformen

Die Gesamtgenauigkeit beträgt rund 79%. Dieser hohe Wert ist vor allem darauf zurückzuführen, dass die Klasse mit der deutlich grössten Auftretenshäufigkeit (80%) sehr gut erkannt wird. So fällt es für die Gesamtgenauigkeit nicht mehr allzu stark ins Gewicht, dass die beiden restlichen Klassen weniger gut erkannt werden. Der Kappa-Koeffizient der diesen Aspekt berücksichtigt, ist mit 0.39 auch entsprechend tiefer.

#### Fallbeispiel

Beim in Abbildung 37 auf Seite 59 dargestellten Waldbestand, handelt es sich im Vordergrund um einen Mischwald, wobei der Übergang zum Hochwald (im Hintergrund) relativ deutlich erkennbar ist. Im dargestellten Beispiel trifft die manuelle Interpretation eindeutig besser zu. Dies ist vor allem darauf zurückzuführen, dass bei der stereoskopischen manuellen Interpretation die dreidimensionale Information verfügbar ist. Bei der Klassifikation mit *eCognition* fehlt dieser Einbezug der dritten Dimension und macht es schwierig vertikale Strukturen mit einer zufriedenstellenden Genauigkeit zu klassieren.







Übersicht (Blickrichtung von oben links nach rechts unten)

Abbildung 37: Kontrollfläche 6 ("Waldformen")

# 5.3.3. Deckungsgrad und Schlussgrad des Waldes

# 5.3.3.1. Deckungsgrad

Bei der Betrachtung der relativen Häufigkeitsverteilung (Relative Häufigkeitsverteilung des Walddeckungsgrades für die Klassifikation mit eCognition und die manuelle Interpretation) wird ersichtlich, dass bei der Klassifikation mit *eCognition* der Anteil von Klassen mit niedrigerem Deckungsgrad (DG < 50%) deutlich höher ist als bei der manuellen Interpretation, wo die Klasse "DG 51-75%" dominiert.

Klasse	DG < 25%	DG 25 - 50%	DG 51 - 75%	DG > 75%
automatische Klassifikation	5.5%	20.7%	34.3%	39.5%
manuelle Interpretation	1.3%	8.0%	56.6%	34.0%

Tabelle 14:Relative Häufigkeitsverteilung des Walddeckungsgrades für die Klassifi-<br/>kation mit eCognition und die manuelle Interpretation

Die höchste Übereinstimmung wird für die Klasse mit dem höchsten Deckungsgrad erzielt (55% bzw. 47%). Die Übereinstimmung nimmt mit sinkendem Deckungsgrad kontinuierlich ab. Da sich die Häufigkeitsverteilung für die Klassen "DG < 25%", "DG 25-50%" und "DG 51-75%" deutlich unterscheiden, weichen die Übereinstimmungskennzahlen für diese Klassen entsprechend voneinander ab.



	Klasse	DG < 25%	DG 25 - 50%	DG 51 - 75%	DG > 75%	Übereinstimmung
	DG < 25%	10819	11620	4903	4214	34.3%
manuelle Interpretation	DG 25 - 50%	24952	64773	52575	53472	33.1%
	DG 51 - 75%	86280	334836	507082	454145	36.7%
	DG > 75%	13243	92915	271984	452808	54.5%
	Übereinstimmung	8.0%	12.8%	32.5%	46.9%	

Tabelle 15:	Übereinstimmungsm	atrix für den	Walddeckungsgrad

Die Gesamtgenauigkeit liegt mit 42% deutlich unter denjenigen der LANA-Kartiereinheiten und der Waldformen. Der Kappa-Koeffizient ist mit 0.25 ebenfalls deutlich tiefer.

#### 5.3.3.2. Schlussgrad

Bei der Klassifikation mit *eCognition* wird ein deutlich höherer Anteil an gleichmässig geschlossenen Wald als bei der manuellen Interpretation ausgeschieden. Entsprechend sind die Anteile von "locker und räumigem" bzw. "aufgelöstem" Wald geringer.

Klassen	gleichmässig geschlossen	locker & räumig	aufgelöst	gruppiert
automatische Klassifikation	25.9%	41.8%	32.1%	0.2%
manuelle Interpretation	11.1%	47.8%	40.6%	0.5%

Tabelle 16:Relative Häufigkeitsverteilung des Waldschlussgrades für die Klassifika-<br/>tion mit eCognition und die manuelle Interpretation

Die Übereinstimmung ist für die beiden Klassen "locker & räumig" und "aufgelöst" am grössten.



		eCognition Klassifikation				
	Klasse	gleichmässig geschlossen	locker & räumig	aufgelöst	gruppiert	Überein- stimmung
manuelle Interpretation	gleichmässig geschlossen	162800	58596	47892	925	60.2%
	locker & räumig	292385	519965	348174	85	44.8%
	aufgelöst	173679	430999	379751	124	38.6%
	gruppiert	899	4763	4071	2718	21.8%
	Überein- stimmung	25.9%	51.3%	48.7%	70.6%	

Tabelle 17:Übereinstimmungsmatrix für den Waldschlussgrad

Mit einer Gesamtgenauigkeit von 44% und einem Kappa-Koeffizient von 0.13 liegen die Kennzahlen im Bereich des Walddeckungsgrades und damit ebenfalls deutlich unter denjenigen der LANA-Kartiereinheiten bzw. der Waldformen.

### Fallbeispiel

Sowohl Waldschlussgrad wie auch Walddeckungsgrad lassen sich vom Boden aus nur ungenügend erfassen und eine Einteilung bzw. Abgrenzung ist nur mit sehr hohem zeitlichen Aufwand möglich. Die Beurteilung der beiden Klassifikationen bezüglich "Wahrheitsgehalt" ist dementsprechend schwierig. Generell lässt sich sagen, dass durch das Einhalten der Mindestflächen bei der manuellen Interpretation eine Generalisierung der Gegebenheiten erfolgt. Der heterogene Charakter bei der automatischen Klassifikation stimmt eher mit den Eindrücken im Feld überein, wobei die exakte Flächenabgrenzung "vom Boden aus" nicht immer nachvollziehbar ist. Abbildung 38 auf Seite 62 illustriert dies an einem Beispiel. Auf dem Foto ist deutlich zu erkennen, dass der Bestand nicht gänzlich homogen ist. Eine eindeu-



tige Abgrenzung bleibt aber schwierig. Die geäusserten Feststellungen haben sowohl für den Walddeckungsgrad als auch für den Waldschlussgrad Gültigkeit.



Luftbild (CIR-Orthophoto)



5.3.4. Rasendeckungsgrad

Tabelle 18 zeigt, dass bei der automatischen Klassifikation der Anteil der Klasse "DG\_Ra < 33%" deutlich grösser ist als bei der manuellen Interpretation. Demgegenüber ist der Anteil der Klasse > 66% bei der manuellen Interpretation deutlich höher.

	DG_Ra < 33%	DG_Ra 34-66%	DG_Ra 67-100%
automatische Klassifikation	50.4%	32.6%	17.0%
manuelle Interpretation	2.6%	20.6%	76.7%

Tabelle 18:Relative Häufigkeitsverteilung des Rasendeckungsgrades für die Klassifi-<br/>kation mit eCognition und die manuelle Interpretation

Entsprechend den Unterschieden bei der Häufigkeitsverteilung sind auch die relativen Übereinstimmungen äusserst gering. Zu beachten ist aber, dass bei der manuellen Interpretation fast 90% der Klasse "DG\_Ra > 33%" auch bei der Klassifikation mit *eCognition* dieser Klasse zugeordnet wurden. Diese hohe Übereinstimmung ist aber nur eine Scheinübereinstimmung, da bei der manuellen Interpretation nur 2.6% der gesamten Rasenfläche dieser Klasse zugeordnet wurden. Bei der automatischen





		eCognition Klassifikation			
	Klasse	DG_Ra < 33%	DG_Ra 34-66%	DG_Ra 67-100%	Überein- stimmung
uc	DG_Ra < 33%	15914	1072	919	88.9%
nanuelle erpretati	DG_Ra 34-66%	88608	15709	35604	11.2%
n Inte	DG_Ra 67-100%	237555	204346	78492	15.1%
	Überein- stimmung	4.7%	7.1%	68.2%	

sind es hingegen über 50%. Dementsprechend beträgt die Kennzahl, bezogen auf die Klassifikation mit *eCognition* nur 4.7%.

Tabelle 19: Übereinstimmungsmatrix für den Rasendeckungsgrad

Auch die Gesamtgenauigkeit und der Kappa-Koeffizient sind mit 16% bzw. 0.06 als sehr tief einzustufen.

Die terrestrische Kontrolle hat gezeigt, dass bei der Klassifikation mit *eCognition* der Rasendeckungsgrad systematisch unterschätzt wird. Die terrestrische Kontrolle zeigte, das der durchschnittliche Rasendeckungsgrad deutlich höher ist, als bei der automatischen Klassifikation ausgewiesen wurde. Es scheint, dass bei der automatischen Klassifikation unterschiedliche Grastypen bzw. durch Hirsche unterschiedlich genutzte Flächen klassiert werden. Zusätzlich werden die Rohbodenanteile bei der



Klassifikation mit eCognition durch einen gewissen Überstrahlungseffekt überschätzt.

DG\_Ra < 33% DG\_Ra 33-66% DG\_Ra > 66%





Luftbild (CIR-Orthophoto)



eCognition Klassifikation



Übersicht (Blickrichtung von oben links nach rechts unten)

Abbildung 39: Kontrollfläche 12 ("Rasendeckungsgrad")

5.4.

# Schlussfolgerungen

Der Detaillierungsgrad bei der Klassifikation mit *eCognition* ist deutlich höher als bei der manuellen Interpretation. Dies ist darauf zurückzuführen, dass die minimale Flächengrösse bei der Klassifikation mit *eCognition* deutlich kleiner ist. Das Einhalten der Mindestflächenkriterien (vgl. Tabelle 20 auf Seite 64) bei der manuellen Interpretation hat einen generalisierenden Einfluss auf das Endergebnis. Kleinräumige Mosaikstrukturen werden deshalb nur bei der Klassifikation mit *eCognition* detailliert klassiert.

Standardmerkmal	Mindestfläche		
Wald	0.2 ha		
Vegetationsbedeckte Nichtwaldflächen	0.2 ha Ausnahmen: 0.1 ha für Moore, Gebüsche		
Offene natürliche Rohbodenstandorte	0.5 ha		

Tabelle 20: Mindestflächenkriterien für die manuelle Interpretation



Für jede Kontrollfläche wird eine Beurteilung der Richtigkeit angeführt. Es wird unterschieden zwischen geometrischer und inhaltlicher Qualität. Die Skala reicht von richtig interpretiert/klassifiziert (+++) bis falsch interpretiert/klassifiziert (---) (Zusammenfassung Tabelle 21; detaillierte Beurteilung jeder Kontrollfläche siehe Anhang B).

Kontrollfläche		manuelle Interpretation		Klassifikation eCognition	
		Beurteilung Geometrie	Beurteilung Inhalt	Beurteilung Geometrie	Beurteilung Inhalt
1	Walddeckungsgrad	+++	++	++	÷
2	Walddeckungsgrad/- Schlussgrad	++		++	
3	Walddeckungsgrad/- Schlussgrad	++		++	
4	Waldform	+	++	+++	++
5	Walddeckungsgrad/- Schlussgrad	++		++	
6	Waldform	+++	+++	+++	
7	Rasendeckungsgrad	+	++	+++	+
8	Rasendeckungsgrad	+	+++	+	+
9	LANA Kartiereinheiten	++	++		100 Mar 100
11	LANA Kartiereinheiten	+	++	+++	+++
12	Rasendeckungsgrad	+	++	+++	÷
13	Waldform	++	++	++	++
14	Rasendeckungsgrad	+++	++	+++	++
15	Walddeckungsgrad/- Schlussgrad	++		+++	
16	LANA Kartiereinheiten	+	++	+++	+++
17	LANA Kartiereinheiten	+	++	+++	+++
19	Waldform	+	++	+++	+
20	LANA Kartiereinheiten	++	++	+	÷
21	LANA Kartiereinheiten	++	+++	+	+
22	LANA Kartiereinheiten	++	+++	+	+

 Tabelle 21:
 Qualitative Beurteilung der Kontrollflächen

Die **fehlende 3-dimensionale Sichtweise** bei der Klassifikation mit *eCognition* wirkt sich zum Teil negativ auf das Klassifikationsergebnis aus. Dies gilt vor allem für die Erkennung von vertikalen Strukturen, welche bei der stereoskopischen manuellen Interpretation deutlich besser erkannt werden können.

Eine weitere Unsicherheit bei der Klassifikation mit *eCognition* betrifft **stark beschattete** Gebiete. Die spektrale Information verunmöglicht zum Teil eine Klassifikation. Bei der manuellen Interpretation können solche Flächen zum Teil noch augewertet werden.

# $L\!AN\!A$ -Kartiereinheiten

Die LANA-Kartiereinheiten werden von beiden Interpretationsverfahren mit hoher Übereinstimmung erfasst. Mit der *eCognition*-Klassifikation wird ein sehr



hoher Detaillierungsgrad erreicht und damit auch kleinflächige Strukturen abgebildet. Problematischer als bei der manuellen Interpretation gestaltet sich die Auswertung von stark beschatteten Gebieten.

#### Waldformen

Der Hochwald wird von beiden Verfahren sehr gut und mit einer hohen Ubereinstimmung erkannt. Die Abgrenzung von Gebüschwald zu gemischten Wald erfolgt bei der manuellen Interpretation mit einer höheren Zuverlässigkeit. Dies ist auf das Fehlen der dreidimensionalen Sichtweise bei der Klassifikation mit *eCognition* zurückzuführen, was die Erkennung von vertikalen Strukturen grundsätzlich erschwert.

#### Walddeckungsgrad und Waldschlussgrad

Vom Boden aus sind die unterschiedlichen Interpretationsergebnisse nur sehr schwierig zu beurteilen; es kann deshalb kein abschliessendes Urteil über die Qualität abgegeben werden. Bei der manuellen Interpretation werden grössere Flächen zusammengefasst, wogegen bei der Klassifikation mit *eCognition* kleiner Flächen ausgeschieden werden und ein heterogeneres Bild abgeben.

#### Rasendeckungsgrad

Bei der Klassifikation mit *eCognition* wurde der Rasendeckungsgrad systematisch unterschätzt. Mit der manuellen Interpretation können zuverlässigere Aussagen über den Rasendeckungsgrad gemacht werden. Einerseits werden die Rohbodenanteile bei der Klassifikation mit *eCognition* durch einen gewissen Überstrahlungseffekt überschätzt und andererseits werden eher unterschiedliche Gräser bzw. Zustand der Rasenvegetation (abgefressen / nicht abgefressen) kartiert.

Zusammenfassend kann gesagt werden, dass der geometrische Detaillierungsgrad bei der Klassifikation deutlich höher ist als bei der manuellen Abgrenzung. Dies ist einerseits durch die Interpretationsrichtlinien der Interpretation und andererseits durch die technische Grenze bei der Abgrenzung mit Tuschstift auf Folie bedingt. Die technische Grenze bei der Klassifikation ist die Pixelgrösse des digitalen Bildmaterials. Mosaikartige Strukturen können daher detaillierter und genauer abgegrenzt bzw. segmentiert werden.

Mosaikartige Bodenbedeckungen werden bei der manuellen Interpretation in einem zweiten Schritt nach der Abgrenzung erfasst. Diese Beschreibung der Flächen erlaubt eine qualitative Beurteilung der Homogenität der Flächen, aber keine geometrische Quantifizierung.



# 6. **Resultate und Ausblick**

# 6.1. Resultate

Mit den im Rahmen des Teilprojektes B gemachten Erfahrungen können die folgenden Feststellungen gemacht werden:

# 6.1.1. Herstellung von digitalen Orthobildern

Für die Herstellung von digitalen Orthophotos aus Bildern der SNP-Befliegung 2000 können die anlässlich der SNP-Befliegung 1988 signalisierten Passpunkte verwendet werden. Etwa 70% dieser Punkte sind für diesen Zweck brauchbar. Die erreichbare Genauigkeit mit solchen Punkten liegt in den meisten Fällen klar unter 50 cm.

Mit einer Verdichtung der aus den 1988-er Bildern übertragenen Punkte durch zusätzliche, mit GPS eingemessenen Passpunkten kann eine Genauigkeit im Bereich von 25 cm erreicht werden. GPS-Passpunkte können jederzeit nachträglich eingemessen werden. Deren Verteilung kann bedarfsgerecht gewählt werden.

# 6.1.2. Digitale Bildklassifikation

Wie bei einer manuellen Bildinterpretation sind auch beim hier vorgestellten digitalen, objektorientierten Klassifikationsverfahren **hierarchische Abstufungen** in den zu kartierenden Bodenbedeckungsklassen möglich. Solche Abstufungen sind vergleichsweise **einfach** durchzuführen.

Der **geometrische Detaillierungsgrad** ist deutlich **höher** als bei der manuellen Interpretation. Allerdings ist darauf hinzuweisen, dass die Einhaltung von vorgegebenen Mindestflächen einen generalisierenden Einfluss hat.

Die **fehlende dreidimensionale Sichtweise** bei der digitalen Bildklassifikation wirkt sich negativ aus. Vertikale Strukturen können kaum erkannt werden, dies im Gegensatz zur stereoskopischen manuellen Interpretation. Mit der Verwendung eines kombinierten Laser-Gelände-/-Oberflächenmodells könnte dieser Mangel allerdings grösstenteils behoben werden.

In Gebieten mit **Schlagschatten** ist die spektrale Information ungenügend, was eine digitale **Klassifikation erschwert** oder gar verhindert. Ein erfahrener Interpret hingegen kann auch solche Gebiete oft korrekt kartieren.

Mit der neuesten Version der verwendeten Software *eCognition* ist eine bestimmte **Klassifikation** jederzeit absolut identisch **reproduzierbar**.

Eine digitale Klassifikation kann nicht *voll*automatisch durchgeführt werden. Auch hier - wie bei einer manuellen Interpretation - sind Fachwissen und Erfahrung des Operateurs unverzichtbar.

Das hier angewandte Verfahren und die eingesetzten Software *eCognition* (Version 2.0) sind relativ neu. Es wurden weltweit erst wenige vergleichbare Projekte durchgeführt. Um gültige Aussagen zu machen, welche Qualität einer Bodenbedeckungsklassifikation sich über das gesamte Parkgebiet erzielen liesse, sind weitere Arbeiten in Gebieten mit anderen Bodenbedeckungsklassen und anderer Topogra-



phie notwendig. Es ist aber davon auszugehen, dass die Qualität der Resultate sich nicht wesentlich ändern würde.

# 6.2. Ausblick

Wie aus Kapitel 5 klar hervorgeht, haben beide Verfahren - die manuelle Bildinterpretation und die digitale Bildklassifikation - ihre spezifischen Stärken und Schwächen. Welchem Ansatz der Vorzug gegeben werden soll, hängt unmittelbar von der jeweiligen Fragestellung ab und kann nicht generell gesagt werden.

Die Kosten für eine digitale, objektorientierte Klassifikation wie sie hier durchgeführt wurde betragen pro km<sup>2</sup> maximal CHF 2'500.-. Bei steigender Gebietsgrösse werden diese Kosten tendenziell geringer. Im genannten Betrag inbegriffen sind die Ausarbeitung des Interpretationsschlüssels und die eigentliche Bildauswertung. Nicht berücksichtigt sind die Herstellung des digitalen Orthobildes sowie weitere Aufwendungen wie Projektmanagement, Datenaufbereitung und Dokumentation. Diese Kostenfaktoren sind vom gewählten Interpretationsverfahren unabhängig.

Für eine Bodenbedeckungskartierung des SNP würde wohl ein kombiniertes Verfahren die besten Resultate hervorbringen. Da die digitale, objektorientierte Bildklassifikation ein neues Verfahren darstellt, mit dem erst wenig Erfahrung gesammelt wurde, müsste ein solch kombiniertes Verfahren bei einer konkreten Problemstellung in enger Zusammenarbeit zwischen Experten der manuellen Bildinterpretation und solchen der digitalen Klassifikation ausgearbeitet werden.



# Literaturverzeichnis

- Baatz, M., Schäpe, A. (2000): Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation, in: Strobl, J., Blaschke, T., Griesebner, G. (Hrsg.): Angewandte Geographische Informationsverarbeitung XII - Beiträge zum AGIT-Symposium Salzburg 2000, 12-23, H. Wichmann Verlag, Heidelberg.
- [2] Blaschke, T. (2000): Ohne Salz und Pfeffer. Objektorientierte Bildanalyse, eine Revolution in der Fernerkundung, in: GeoBIT, Nr. 2, 2000, Wichmann Verlag, Heidelberg, 30-32.
- [3] Blaschke, T., Lang, S., Lorup, E., Strobl, J., Zeil, P. (2000): Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications, in: Cremers, A., Greve, K. (Eds.): Environmental Information for Planning, Politics and the Public, Metropolis Verlag, Marburg, Vol. II, 555-570.
- [4] Definiens (2002): eCognition User Guide. Version 2.1, München.
- [5] Definiens (2002): eCognition User Guide. Version 3.0, München.
- [6] de Kok, R. (2001): Objektorientierte Bildanalyse. Ein Lösungsansatz für den automatisierten Einsatz sehr hoch auflösender Satellitendaten für forstliche Fragestellungen. Dissertation, Fakultät Wissenschaftszentrum Weihenstephan für Ernährung, Landnutzung und Umwelt der Technischen Universität München.
- [7] Haarmann, B. (2001): Untersuchung zur Verwendbarkeit der Software eCognition für Zwecke der CORINE Landnutzungs-Klassifikation. Diplomarbeit, Institut für Photogrammetrie und Ingenieurvermessung der Universität Hannover.
- [8] Haller R. (2002): Persönliche Mitteilung.
- [9] Haller R., Imfeld St. (2002): Persönliche Mitteilung.
- [10] Itten, K.I. (1979): Grossräumige Inventuren mit Landsat-Erderkundungssatelliten in der Schweiz. Habilitationsschrift, Philosophische Fakultät II der Universität Zürich.
- [11] Kraus, K. (1986): Photogrammetrie. Band 1: Grundlagen und Standardverfahren. Dümmler Verlag, Bonn.
- [12] Kraus, K. (1990): Fernerkundung. Band 2: Auswertung photographischer und digitaler Bilder. Dümmler Verlag, Bonn.
- [13] LANA (Arbeitsgemeinschaft Naturschutz der Landesämter, Landesanstalten und ehemeliger Institute für Landschaftsforschung und Naturschutz) (1995): Systematik der Biotoptypen- und Nutzungstypenkartierung (Kartieranleitung). Standard-Biotoptypen und Nutzungstypenkartierung für die Bundesrepublik Deutschland. Bundesamt für Naturschutz, Bonn - Bad Godesberg.
- [14] Meyer, P. (1990): Segmentierung und symbolische Beschreibung als Grundlage zur Klassifikation landwirtschaftlicher Kulturen in einem Multispektralscanner-Datensatz. Dissertation, Geographisches Institut der Universität Zürich.
- [15] Meinel, G., Neubert, M., Reder, J. (2001): Pixelorientierte versus segmentorientierter Klassifikation von IKONOS-Satellitenbilddaten. Ein Methodenvergleich. Zeitschrift für Photogrammetrie, Fernerkundung und





Geoinformation, Nr. 3, 2001, 157-170.

- [16] Neubert, M. (2001): Segment-based analysis of high resolution satellite and laser scanning data, in: Hilty, L.M., Gilgen, P.W. (Eds.): Sustainability in the Information Society. Proceedings of the 15th International Symposium Informatics for Environmental Protection, Zurich, October 10-12, 2001, Metropolis Verlag, Marburg, 379-386.
- [17] Neubert, M., Meinel, G. (2002): Segmentbasierte Auswertung von IKO-NOS-Daten. Anwendung der Bildanalyse Software eCognition auf unterschiedliche Testgebiete, in: Blaschke, T. (Hrsg.): Fernerkundung und GIS: Neue Sensoren - innovative Methoden. H. Wichmann Verlag, Heidelberg, 108-117.
- [18] Scherrer, H.U. (1989): Vorstudie über die Anwendung der Fernerkundung im Schweizerischen Nationalpark, Projektbericht (unpubliziert), Nesslau.
- [19] Schmidt, R. (2000): Untersuchung des Bildanalysesystems eCognition. Diplomarbeit, Institut für Photogrammetrie und Ingenieurvermessung der Universität Hannover.
- [20] SNP (Schweizerischer Nationalpark) (2000): Luftbild-Projekt 2000 Schweizerischer Nationalpark, Teilprojekt A, Ergebnisbericht. Dezember 2000
- [21] Ziegler, M. (2002): Laserscannerdaten und hochauflösende Satellitenbilddaten für Belange der Planung mit einer Detailstudie für den Einsatz im Bereich Forstinventur. Auszüge aus der Dissertation von Mag. Michaela Ziegler.

http://www.kfunigraz.ac.at/geowww/forschung/fo\_fern/beispiele/ziegler2/ziegler2.htm#07.22.5.02 (Stand 16.8.02).



# Anhang A Beispielkarten

In diesem Anhang werden alle Klassifikationsresultate aus Kapitel 4. 'Digitale Bodenbedeckungsklassierung' über das gesamte Untersuchungsgebiet dargestellt.



# A.1 Kartiereinheiten gemäss LANA (1995)




#### A.2 Waldfläche und Bestandeslückenkartierung





L

t

#### A.3 Waldformen





t

# A.4 Waldformen (vertikale Struktur)





-

F

ŀ

-

### A.5 Deckungsgrad





1

t

## A.6 Deckungsgrad (gruppierte Klassen)





## A.7 Schlussgrad





1

l

t

## A.8 Deckungsgrad der Rasengesellschaften





# Anhang B Kontrollflächen

# B.1 Übersicht









#### Abbildung 41: Legenden

Neben einer Beschreibung der Kontrollflächen wird die Qualität deren Interpretation bzw. Klassifikation beurteilt. Es wird dabei unterschieden zwischen geometrischer und inhaltlicher Qualität. Die Skala reicht von richtig interpretiert/klassifiziert (+++) bis falsch interpretiert/klassifiziert (- - -).

Der Begriff "Interpretation" wird verwendet für die manuelle Luftbildinterpretation, der Begriff "Klassifikation" für die automatische Klassifikation mit *eCognition*.



## B.2 Kontrollfläche 1 – Walddeckungsgrad







automatische Klassifikation

manuelle Interpretation

Der Walddeckungsgrad ist im Feld schwierig zu beurteilen. Eine gewisse Heterogenität wird aus dem Luftbild ersichtlich. Bei der Klassifikation ist der Deckungsgrad im Südteil mit 51%-75% sicherlich zu hoch (siehe (1)).

	manuelle Interpretation	automatische Klassifikation
Geometrie	++	++
Inhalt	++	+



#### Kontrollfläche 2 - Walddeckungsgrad und Waldschlussgrad B.3









manuelle Interpretation





Luftbild (CIR-Orthophoto)

automatische Klassifikation

Walddeckungsgrad und Waldschlussgrad sind im Feld schwierig zu beurteilen. Eine gewisse Heterogenität wird aus dem Orthobild ersichtlich. Die Klassenzuteilung der beiden Verfahren kann durch die terrestrische Kontrolle qualitativ nicht abgeschätzt werden.

	manuelle Interpretation	automatische Klassifikation
Geometrie	++	++
Inhalt	?	?



## B.4 Kontrollfläche 3 - Walddeckungsgrad und Waldschlussgrad



manuelle Interpretation

Luftbild (CIR-Orthophoto)

automatische Klassifikation

Walddeckungsgrad und Waldschlussgrad sind im Feld schwierig zu beurteilen. Eine gewisse Heterogenität wird aus dem Orthobild ersichtlich. Die Klassenzuteilung bzw. die Abgrenzung der beiden Verfahren kann durch die terrestrische Kontrolle qualitativ nicht abgeschätzt werden.

	manuelle Interpretation	automatische Klassifikation
Geometrie	++	++
Inhalt	?	?



#### B.5 Kontrollfläche 4 – Waldform







manuelle Interpretation

Luftbild (CIR-Orthophoto)

automatische Klassifikation

Bei der Kontrolle im Feld wurde dieser Bestand eher als gemischt beurteilt. Entlang der Strasse ist vor allem die aufrechte Bergföhre vertreten. Gegen den Abhang hin (Richtung Bach) dominiert die Legföhre zunehmend. Bei der Klassifikation wurde ein Teil der Strasse und der Brücke falsch klassiert und dem Hochwald beziehungsweise Gebüschwald zugeordnet. Die geometrische Abgrenzung ist bei der Klassifikation detaillierter. Die Attributierung der Interpretationsfläche enthält allerdings den Rohbodenanteil (40%) und den Legföhren- (90%) beziehungsweise Bergföhrenanteil (10%). Die Grenzziehung der Klassifikation spiegelt die Realität besser wieder. Die Interpretation beschreibt den Flächeninhalt umfassender.

	manuelle Interpretation	automatische Klassifikation
Geometrie	+	+++
Inhalt	++	++



#### B.6 Kontrollfläche 5 - Walddeckungsgrad und Waldschlussgrad



Walddeckungsgrad und Waldschlussgrad sind im Feld wiederum schwierig zu beurteilen. Eine gewisse Heterogenität wird aus dem Orthobild ersichtlich. Die Klassenzuteilung bzw. die Abgrenzung der beiden Verfahren kann durch die terrestrische Kontrolle qualitativ nicht abgeschätzt werden. Auch hier wurden Teile der Strasse falsch klassiert.

	manuelle Interpretation	automatische Klassifikation
Geometrie	++	++
Inhalt		



#### B.7 Kontrollfläche 6 - Waldform



manuelle Interpretation

Luftbild (CIR-Orthophoto)

automatische Klassifikation

Beim abgebildeten Waldbestand handelt es sich um einen Misch- oder Gebüschwald (1), wo der Übergang zum Hochwald (2) stereoskopisch und im Feld deutlich erkennbar ist. Im dargestellten Beispiel trifft die manuelle Interpretation eindeutig besser zu. Durch die fehlende dritte Dimension konnte bei der Klassifikation zwischen den Waldformen nicht differenziert werden.

	manuelle Interpretation	automatische Klassifikation
Geometrie	+++	+++
Inhalt	+++	2



#### B.8 Kontrollfläche 7 - Rasendeckungsgrad



manuelle Interpretation

Luftbild (CIR-Orthophoto)

automatische Klassifikation

Der ausgewiesene Rasendeckungsgrad der Interpretation stimmt eindeutig besser mit den Eindrücken im Feld überein. Die Grenzziehung ist bei der Klassifikation detaillierter. Der Baumanteil von 10% ist in der Flächenbeschreibung der Interpretation enthalten. Bei der Klassifikation wurde der Rasendeckungsgrad eindeutig unterschätzt. Abgefressener Rasen wurde als Rohboden fehlklassisiert, daher die zu geringe Rasendeckung.

	manuelle Interpretation	automatische Klassifikation
Geometrie	+	+++
Inhalt	++	+



#### B.9 Kontrollfläche 8 - Rasendeckungsgrad



manuelle Interpretation

Luftbild (CIR-Orthophoto)



Der ausgewiesene Rasendeckungsgrad der manuellen Interpretation stimmt besser mit den Eindrücken im Feld überein. Bei der Klassifikation wurde der Rasendekkungsgrad unterschätzt. Abgefressener Rasen wurde als Rohboden fehlklassisiert, daher die zu geringe Rasendeckung. Die mosaikartige Struktur bei der Klassifikation ist eher auf unterschiedliche Rasentypen zurückzuführen. Am westlichen Rand der Rasenfläche ist die Problematik des Schattens bei der Klassifikation zu sehen. Der Schatten wurde hier falsch dem Wald zugeordnet.

	manuelle Interpretation	automatische Klassifikation	
Geometrie	+	+	
Inhalt	+++	+	



#### B.10 Kontrollfläche 9 - LANA-Kartiereinheiten



manuelle Interpretation





Luftbild (CIR-Orthophoto)

automatische Klassifikation

Die Bestandeslücke, welche bei der Interpretation als solche erkannt wurde, konnte anlässlich der terrestrischen Kontrolle eindeutig identifiziert und verifiziert werden. Bei der Klassifikation reicht die spektrale Information des Schattengebietes nicht mehr aus, um eine korrekte Klassifikation zu gewährleisten.

	manuelle Interpretation	automatische Klassifikation
Geometrie	++	
Inhalt	++	





#### B.11 Kontrollfläche 11 - LANA-Kartiereinheiten







automatische Klassifikation

manuelle Interpretation

Luftbild (CIR-Orthophoto)

Bei der Interpretation werden die kleinflächigen rottenartigen Strukturen und vereinzelte Legföhren nicht erfasst. Im Gegensatz dazu bleibt bei der Klassifikation die mosaikartige Struktur erhalten. Im geschlossenen Hochwald mit klar abzugrenzenden Waldrändern sind die Unterschiede gering. Die Bestockung auf der freien Fläche ist in der Flächenbeschreibung der Interpretation erfasst (Baumanteil 10% bzw. 20%).

	manuelle Interpretation	automatische Klassifikation
Geometrie	+	+++
Inhalt	++	+++



#### B.12 Kontrollfläche 12 - Rasendeckungsgrad







Luftbild (CIR-Orthophoto)



automatische Klassifikation

Der ausgewiesene höhere Rasendeckungsgrad der Interpretation stimmt besser mit den Eindrücken im Feld überein. Bei der Klassifikation mit *eCognition* wurde der Rasendeckungsgrad unterschätzt. Die mosaikartige Struktur bei der Klassifikation ist eher auf unterschiedliche Rasentypen zurückzuführen. Der zu geringe Rasendekkungsgrad bei der Klassifikation ist durch stark abgefressene Gräser bedingt, wodurch der Rohbodenanteil überschätzt wurde. Der Gebüschanteil ist in der inhaltlichen Beschreibung der Interpretationflächen festgehalten.

	manuelle Interpretation	automatische Klassifikation
Geometrie	+	+++
Inhalt	++	+





### B.13 Kontrollfläche 13 – Waldform







manuelle Interpretation

Luftbild (CIR-Orthophoto)

automatische Klassifikation

Die Feldkontrolle ergab, dass diese Waldstruktur sehr heterogen aufgebaut ist. Auf kleinstem Raum wechseln sich Legföhren und aufrechte Bergföhren ab. Klare Abgrenzungen sind kaum zu erkennen. So gesehen sind beide Interpretationsergebnisse "gleich richtig " bzw. "gleich falsch".

	manuelle Interpretation	automatische Klassifikation
Geometrie	++	++
Inhalt	++	++





### B.14 Kontrollfläche 14 - Rasendeckungsgrad



manuelle Interpretation



Luftbild (CIR-Orthophoto)



automatische Klassifikation

Der ausgewiesene höhere Rasendeckungsgrad der Interpretation stimmt besser mit den Eindrücken im Feld überein. Bei der Klassifikation mit *eCognition* wurde der Rasendeckungsgrad unterschätzt. Stark abgefressener Rasen führte zu einer Überschätzung des Rohbodenanteils bei der Klassifikation und somit zu einem zu geringem Rasendeckungsgrad.

	manuelle Interpretation	automatische Klassifikation
Geometrie	+++	+++
Inhalt	++	++



## B.15 Kontrollfläche 15 - Walddeckungsgrad und Waldschlussgrad



Walddeckungsgrad und Waldschlussgrad sind im Feld nur schwierig zu beurteilen. Die Klassenzuteilung bzw. die Abgrenzung der beiden Verfahren kann durch die terrestrische Kontrolle qualitativ nicht abgeschätzt werden. Die Klassifikation weist in schattigen Gebieten eher einen höheren Deckungsgrad bzw. Schlussgrad aus.

	manuelle Interpretation	automatische Klassifikation
Geometrie	++	+++
Inhalt	?	?



#### B.16 Kontrollfläche 16 - LANA-Kartiereinheiten







manuelle Interpretation

Luftbild (CIR-Orthophoto)

automatische Klassifikation

Bei der Interpretation verschwindet die kleinflächige Struktur gänzlich, wogegen bei der Klassifikation die mosaikartige Struktur wiedergegeben wird. Zu berücksichtigen ist, dass die Rohbodenanteile an dieser extrem exponierten Hanglage sehr stark überstrahlen, womit der Rohbodenanteil bei der Klassifikation überschätzt wird. Bei der Interpretation ist der Rohbodenanteil von 70% durch die Attributierung wiedergegeben.

	manuelle Interpretation	automatische Klassifikation
Geometrie	+	+++
Inhalt	++	+++



## B.17 Kontrollfläche 17 - LANA-Kartiereinheiten







manuelle Interpretation

Luftbild (CIR-Orthophoto)

automatische Klassifikation

Die heterogene Struktur und die mosaikartige Verteilung der Einzelbäume bzw. Kleinstbaumgruppen werden von der Klassifikation gut erfasst. Bei der Interpretation wir die ganze Fläche zusammengefasst. Der Anteil Rohboden (20%) ist in der Attributierung erfasst.

	manuelle Interpretation	automatische Klassifikation
Geometrie	+	+++
Inhalt	++	+++





#### B.18 Kontrollfläche 19 – Waldform



manuelle Interpretation

Luftbild (CIR-Orthophoto)

automatische Klassifikation

Gemäss der Beurteilung im Feld handelt es sich im unteren Bereich um einen Hochwald. Gegen den Berg hin geht der Hochwald langsam in einen gemischten Bestand über. Der Korridor in der Mitte wird von der manuellen Interpretation richtigerweise als Gebüschwald identifiziert. Bei der Klassifikation wird der Korridor wegen dem einfallenden Schatten nicht erkannt.

	manuelle Interpretation	automatische Klassifikation
Geometrie	+	+++
Inhalt	++	+





## B.19 Kontrollfläche 20 - LANA-Kartiereinheiten







manuelle Interpretation

Luftbild (CIR-Orthophoto)

automatische Klassifikation

Bei der Klassifikation wird der gesamte Schatten als Wald klassiert. Dies hat zur Folge, dass zuviel Wald klassiert wird. Bei der Interpretation können diese schattigen Gebiete besser ausgewertet werden.

	manuelle Interpretation	automatische Klassifikation
Geometrie	++	+
Inhalt	++	+



#### B.20 Kontrollfläche 21 - LANA-Kartiereinheiten



manuelle Interpretation

Luftbild (CIR-Orthophoto)

automatische Klassifikation

Diese Fläche wird durch einen hohen Totholzanteil charakterisiert. Bei der Klassifikation wird diese Fläche der Klasse Rohboden, bei der Interpretation der Klasse Wiese zugerechnet. Vom Gesamteindruck her bei der Feldkontrolle handelt es sich um eine Rasenfläche.

	manuelle Interpretation	automatische Klassifikation
Geometrie	++	+
Inhalt	+++	+





#### B.21 Kontrollfläche 22 - LANA-Kartiereinheiten







manuelle Interpretation

Luftbild (CIR-Orthophoto)

automatische Klassifikation

Der Eigenschatten des Waldbestandes reicht über den Waldrand hinaus in die angrenzende Ebene hinein. Für die Klassifikation liefern Textur und spektrale Eigenschaften zu wenig Informationen, um eine korrekte Abgrenzung des Waldbestandes durchzuführen. Bei der manuellen Interpretation können diese schattigen Gebiete richtig ausgewertet werden.

	manuelle Interpretation	automatische Klassifikation
Geometrie	++	+
Inhalt	+++	+

