
Hausarbeit

"Hybride Klassifikation eines Luftbildausschnittes der Stadt Trier"

Seminar Praxis Methoden der Digitalen Bildverarbeitung
Dozent: Dr. Thomas Jarmer
Wintersemester 2009/2010

Universität Osnabrück
Institut für Geoinformatik

Bearbeiter:
Robert Daniels
Susanne Niemuth

31.03.2010



Inhalt

Inhalt	1
1 Einleitung	2
2 Datengrundlage	2
3 Hybride Klassifizierung	3
3.1 Überwachte Klassifizierung	4
3.1.1 Beschreibung	4
3.1.2 Vorgehen für den Ausschnitt Trier	6
3.2 Unüberwachte Klassifizierung	7
3.2.1 Beschreibung	7
3.2.2 Vorgehen für den Ausschnitt Trier	9
3.3 Ergebnis der hybriden Klassifizierung	10
3.4 Ergebnisverbesserung	12
3.4.1 Feature Space	13
3.4.2 Nutzung des DEM im Spatial Modeler für die Bestimmung der Landnutzungsklasse „Wein“	15
3.4.3 Thresholding	19
4 Gesamtergebnis	21
5 Zusammenfassung und Fazit	23
6 Quellen	24
7 Anhang	25

Abbildungen

Abbildung 1: Für die Klassifizierung betrachtetes Subset des Landsat-Bildes Trier (Falschfarbeninfrarotbild mit den Kanälen 2, 3 und 4 Grün - Rot - Infrarot)	3
Abbildung 2: Clusterbildung und Zuordnungsprinzipien der überwachten Klassifizierung	5
Abbildung 3: Erstellung von AOIs mit Hilfe des Region Growing Tools	7
Abbildung 4: Beispiel für einen zweidimensionalen Merkmalsraum (LEXIKON DER FERNERKUNDUNG, 2009)	8
Abbildung 5: Subset der potentiell als 'Stadt' zu klassifizierenden Bereiche	9
Abbildung 6: Signaturen der hybriden Klassifizierung	11
Abbildung 7: Ergebnis der hybriden Klassifizierung	11
Abbildung 8: Fehlerhafte Klassifizierung des Ausschnittes Trier mit der Klasse 'Wein' (violett) nur anhand der spektralen Signatur	13
Abbildung 9: Feature Space für die Klassen der hybriden Klassifizierung	14
Abbildung 10: Schema des Spatial Modelers und des	16
Abbildung 11: Mit dem Spatial Modeler umgesetzte Entscheidungsfindung für die Klasse 'Wein'	17
Abbildung 12: Bereiche des Ausschnittes Trier mit einer Hangneigung > 19 % und einer Ausrichtung von Südost bis Südwest (weiß dargestellt)	18
Abbildung 13: Klassifizierung ohne (links) und mit (rechts) der Klasse 'Wein' (violett)	19
Abbildung 14: Histogramm des distance image file (ERDAS INC., 1999)	20
Abbildung 15: Ergebnis der hybriden Klassifizierung unter Einbezug des digitalen Höhenmodells	21
Abbildung 16: Attributtabelle des Ergebnisses mit den zusammengefassten Landnutzungsklassen	22

1 Einleitung

Die Klassifizierung ist eine systematische Methode, die die digitale Auswertung von Bilddaten ermöglicht. Anders als bei der Auswertung eines Fernerkundungsbildes durch einen menschlichen Betrachter, dessen visuelle Fähigkeiten nur beschränkt sind, bietet die computerbasierte Auswertung die Möglichkeit einer sehr präzisen Analyse. Dennoch ist es einer Maschine nicht möglich, eine Bildszene auf die Weise zu "verstehen", wie es für den Menschen selbstverständlich ist (ALBERTZ, 2007). Die verschiedenen Ansätze der Klassifizierung bieten nun die Möglichkeit, die automatische Mustererkennung mit der Interpretationsfähigkeit durch den Bearbeiter zu kombinieren.

In der vorliegenden Arbeit soll auf Basis eines Landsat-Bildes der Stadt Trier eine hybride Klassifizierung, welches eine Kombination von überwachtem und unüberwachtem Vorgehen darstellt, durchgeführt und das erzielte Ergebnis kritisch bewertet und gegebenenfalls durch zusätzliche Informationen verbessert werden.

2 Datengrundlage

Die hybride Klassifizierung wurde für ein Landsat-Luftbild von der Stadt Trier und ihres Umlandes durchgeführt. Um die Bearbeitungszeit zu verkürzen, wurde lediglich ein Ausschnitt (Subset) des ursprünglichen Bildes betrachtet (siehe Abbildung 1).

Als Software für alle Arbeitsschritte wurde ERDAS IMAGINE 9.3 der Firma ERDAS, Inc. verwendet. Im Anschluss an die Klassifizierung wurden einige Bereiche des Bildes mit Hilfe eines Digitalen Höhenmodells (**d**igital **e**levation **m**odel [DEM]) zusätzlich untersucht. Dieses DEM lag als Datei im ERDAS IMAGINE Raster-Format .img vor.




Abbildung 1: Für die Klassifizierung betrachtetes Subset des Landsat-Bildes Trier (Falschfarbeninfrarotbild mit den Kanälen 2, 3 und 4 Grün - Rot - Infrarot)

3 Hybride Klassifizierung

Der Begriff der 'hybriden Klassifikation' kann auf unterschiedliche Weise aufgefasst werden. Gemeinsam haben alle Ansätze die Kombination verschiedener Klassifikationsverfahren. So beschreibt PENGLER (2007) eine Auffassung der hybriden Klassifikation als eine Verbindung von analoger und digitaler Auswertung. Dieses bietet den Vorteil, dass die Schwächen der einzelnen Methoden minimiert und die Stärken miteinander verknüpft werden. So ist es möglich, durch den digitalen Ansatz spektrale Signaturen zweifelsfrei zu erkennen und die Ergebnisse zu reproduzieren und zugleich durch den analogen Ansatz

Expertenwissen in die Auswertung einfließen zu lassen.

Ein weiterer Ansatz, der von PENGLER (2007) und auch von ALBERTZ (2005) genannt wird, ist die Verbindung von unüberwachter und überwachter Klassifikation. Hierbei wird z.B. der überwachten Klassifikation eine Cluster-Analyse vorgeschaltet, anhand derer bereits überprüft werden kann, ob sich die gewünschten Klassen überhaupt extrahieren lassen. Weiterhin zeigt sich, ob bestimmte Informationsklassen in weitere Spektralklassen untergliedert werden können und müssen. Letztere Art der hybriden Klassifikation wurde auch in der vorliegenden Arbeit umgesetzt. Hier wurden zunächst für die offensichtlichen Klassen wie Wasser, Gründland etc. AOIs [area of interest] festgelegt. Für besonders heterogene Klassen wie die Klasse 'Stadt' wurde zunächst ein Subset für den potentiell relevanten Bereich definiert und auf ihm eine unüberwachte Klassifizierung mit relativ wenigen Klassen durchgeführt. Durch die Kombination der so gewonnenen spektralen Signaturen mit den aus der zuvor erfolgten überwachten Klassifizierung erhaltenen Informationen konnte eine erneute überwachte Klassifizierung durchgeführt werden. Im Anschluss wurden kleinere Korrekturen wie die Elimination von im Spektralraum nicht eindeutig getrennten Klassen und die Zuhilfenahme des DEM zum Auffinden von Weinbau durchgeführt. Das genaue Vorgehen soll im Folgenden beschrieben werden.

3.1 Überwachte Klassifizierung

3.1.1 Beschreibung

Die überwachte Klassifizierung bezieht in den Prozess der Klasseneinteilung zusätzliche Vorabinformationen ein. Da man davon ausgehen kann, dass verschiedene Landnutzungsklassen eigene, ihnen typische Reflexionseigenschaften in den einzelnen Kanälen besitzen, kann jede Signatur einer Klasse zugeordnet werden.

Hierzu werden vor der eigentlichen Klassifizierung die spektralen Signaturen für verschiedene Objektklassen anhand von Trainingsgebieten definiert. Solche Trainingsgebiete sind Referenzflächen, die als Beispiel für bestimmte Objektklassen bzw. Landnutzungen stehen. Für jede Objektklasse muss mindestens ein Trainingsgebiet festgelegt sein, um Kriterien zur Unterscheidung von anderen Objekten festsetzen zu können. Da die Signaturen für eine Landnutzungsklasse nicht immer dieselben sind, weil sie sich beispielsweise mit den Jahreszeiten oder den atmosphärischen Verhältnissen zum Aufnahmezeitpunkt ändern, müssen für jedes zu klassifizierende Luftbild individuelle Trainingsgebiete festgelegt werden. Um Fehler zu vermeiden, ist es nötig, dass die Trainingsgebiete möglichst homogen sind und dass für sie möglichst zweifelsfrei die vorliegende Landnutzung bekannt ist (ALBERTZ, 2007; DE LANGE, 2005).

Die Zuordnung der verschiedenen Pixel in die zuvor definierten Klassen kann mit verschiedenen Methoden geschehen. Die Clusterbildung und Zuordnungsmethoden der geläufigsten Vorgehensweisen sind in Abbildung 2 dargestellt.




Abbildung 2: Clusterbildung und Zuordnungsprinzipien der überwachten Klassifizierung

Die am häufigsten genutzte Methode ist das so genannte *Maximum-Likelihood-Verfahren* („Verfahren der größten Wahrscheinlichkeit“). Hierzu werden zunächst die Zentren der einzelnen Cluster bestimmt und anschließend für jedes Pixel die Wahrscheinlichkeit berechnet, mit der es zu den vorgegebenen Klassen gehört. Dabei wird vorausgesetzt, dass die Werte im Merkmalsraum um den Klassenmittelpunkt herum normalverteilt sind. Letztendlich wird das Pixel dann der Klasse mit der höchsten Wahrscheinlichkeit zugeordnet. Das Maximum-Likelihood-Verfahren ist relativ rechenaufwändig, liefert jedoch zumeist gute Ergebnisse (ALBERTZ, 2007; DE LANGE, 2005). Da die Rechenleistung der verwendeten Computer heutzutage nicht mehr der begrenzende Faktor ist, stellt das Maximum-Likelihood-Verfahren eine häufig verwendete Methode da.

Das *Minimum-Distance-Verfahren* („Verfahren der nächsten Nachbarschaft“) ist, ebenso wie das Maximum-Likelihood-Verfahren, eine statistische Methode, welche jedoch weniger aufwändig ist. Auch hier wird für jeden Cluster zunächst ein Mittelpunkt bestimmt. Die einzelnen Pixel werden nun der Klasse zugeordnet, zu deren Mittelpunkt sie den geringsten Abstand im Merkmalsraum haben. Wird der Merkmalsraum durch zwei Kanäle aufgespannt, so wird er mit dem Minimum-Distance-Verfahren in Thiessen-Polygone zerlegt. Die Methode ist zwar relativ einfach, da sie jedoch die Streuung der Werte um die Mittelwerte unberücksichtigt lässt, kann es zu Fehleinteilungen kommen (ALBERTZ, 2007; DE LANGE, 2005).

Eine relativ simple Methode der Klassifizierung ist das *Quader-Verfahren* (auch Parallelepiped oder Box Classifier genannt). Hierbei wird davon ausgegangen, dass jedes Trainingsgebiet

bei n Kanälen einen n -dimensionalen Quader im Merkmalsraum bildet. Die Grenzen des Quaders werden jeweils durch den minimalen und den maximalen Wert in einem Kanal festgelegt. Die Klassifizierung geschieht nun durch die Abfrage, ob der Wert eines Pixels innerhalb eines Quaders liegt, andernfalls bleibt das Pixel unklassifiziert. Allerdings kann es vorkommen, dass sich die Quader innerhalb des Merkmalsraumes überlappen. In diesem Fall ist es nötig, sie zu modifizieren (ALBERTZ, 2007; DE LANGE, 2005).

Ein weiteres Verfahren, auf welches an dieser Stelle jedoch nicht weiter eingegangen werden soll, ist die *Hierarchische Klassifizierung*. Dieses Verfahren ist äußerst flexibel, da es in mehreren Schritten durchgeführt wird und bei jedem Schritt neue Entscheidungsregeln festgelegt werden. Dementsprechend ist es jedoch auch sehr aufwändig (ALBERTZ, 2007). Unter ERDAS IMAGINE hat der Benutzer die Möglichkeit, das Verfahren für die überwachte Klassifikation selbst zu wählen. Unter dem Punkt 'Decision Rules' kann er beispielsweise 'parallel-piped' als eine nicht-parametrische Regel verwenden oder bei den parametrischen Verfahren zwischen 'maximum likelihood' oder 'minimum distance' wählen.

3.1.2 Vorgehen für den Ausschnitt Trier

Zunächst wurden für den Bildausschnitt von Trier einige AOIs für die visuell relativ eindeutig erkennbaren Objektklassen wie Wasser, Laub- und Nadelwald oder das Stadtgebiet erstellt. Um die AOIs möglichst genau festzulegen, wurde das 'Region Growing Tool' von ERDAS IMAGINE verwendet. Mit diesem Tool ist es möglich, zusammenhängende Bereiche (Segmente) zu ermitteln, indem ausgehend von einem Zentralpixel alle benachbarten Pixel nach und nach zu einer Fläche aggregiert werden. Dies geschieht so lange, bis die euklidische Distanz im Merkmalsraum, welche zu Beginn definiert wurde, überschritten wird. Unter ERDAS IMAGINE lässt sich dieser Schwellwert sowie die Definition der Pixel-Nachbarschaft unter dem Menüpunkt 'Seed Properties' festlegen (siehe Abbildung 3). Je höher der Wert unter dem Punkt 'Spectral Euclidean Distance' gewählt wird, umso mehr Pixel umfasst die AOI, da auch Pixel, die weiter vom Zentralpixel entfernt sind, in das Segment aufgenommen werden. Welcher Wert letztendlich gewählt wird, hängt von den jeweiligen spektralen Eigenschaften der Nachbarpixel ab.




Abbildung 3: Erstellung von AOIs mit Hilfe des Region Growing Tools

Ein erster überwachter Klassifizierungsdurchlauf ergab jedoch, dass die spektrale Signatur, die durch das Trainingsgebiet für die Klasse 'Stadt' ermittelt wurde, zu heterogen war, um sie mit einer überwachten Klassifizierung erfassen zu können. Um dieses Problem zu umgehen, wurde für den Stadtbereich ein Subset erstellt und dieses unüberwacht klassifiziert. Das genaue Vorgehen ist in Kapitel 3.2.2 näher beschrieben. Im Anschluss hieran wurden die Signaturen kombiniert. Es ergab sich, dass einige Nutzungsklassen, konkret die Klassen Ackerbau und Grünland, bis zu diesem Schritt noch nicht erfasst wurden. Für diese Klassen wurden ebenfalls AOIs festgelegt und ihre spektralen Signaturen so in die Klassifizierung aufgenommen. Das Gesamtergebnis, welches durch die Verbindung der überwachten und der unüberwachten Klassifikation entstand, wird in Kapitel 3.3 beschrieben.

3.2 Unüberwachte Klassifizierung

3.2.1 Beschreibung

Die unüberwachte Klassifizierung, häufig auch als Cluster-Analyse bezeichnet, hat das Ziel, alle Bildelemente einer zuvor definierten Menge von Klassen zuzuordnen. Entscheidend für

die jeweilige Zuordnung ist die Ähnlichkeit der Elemente hinsichtlich ihrer spektralen Eigenschaften. Es ist nicht vorgesehen, den Klassen im Voraus eine Bedeutung zu geben, so dass auch keine Referenzdaten oder Trainingsgebiete benötigt werden (ALBERTZ, 2007). Diese Klassen werden bei ihrer Darstellung im Merkmalsraum (englisch: feature space) auch als 'Cluster' bezeichnet. Bildelemente mit ähnlichen spektralen Eigenschaften befinden sich im Merkmalsraum in direkter Nachbarschaft (DE LANGE, 2005). Ein zweidimensionaler Merkmalsraum ist in Abbildung 4 dargestellt. Hier sind die Pixelwerte eines beliebigen Bildelements für zwei spektrale Kanäle gegeneinander aufgetragen.




Abbildung 4: Beispiel für einen zweidimensionalen Merkmalsraum (LEXIKON DER FERNERKUNDUNG, 2009)

Die unüberwachte Klassifizierung ist ein statistisches Verfahren, welches meist iterativ arbeitet. So wird schrittweise bestimmt, welche Pixel zu einem Cluster gehören und wo die Zentren dieser Cluster liegen (ALBERTZ, 2007). Dieses iterative Vorgehen beruht häufig auf dem K-mean- oder dem ISODATA-Algorithmus (,iterative self-organizing data analysis technique'). Beide Algorithmen arbeiten auf ähnliche Weise: Zunächst wird für jede Klasse ein vorläufiger Cluster-Mittelpunkt bestimmt. Anschließend wird jedes Pixel dem nächstgelegenen Cluster zugeordnet und letztendlich erneut der Mittelpunkt der Cluster bestimmt. Die beiden letzten Schritte werden so oft durchlaufen, bis sich die Verschiebung der Zentren einen zuvor festgelegten Wert unterschreiten oder eine festgelegte Anzahl an Wiederholungen überschritten wird. Das ISODATA-Verfahren ist zusätzlich in der Lage, eine zusätzliche 'split & merge' -Methode zu nutzen. So werden Cluster, denen weniger als eine

definierte Menge an Pixeln zugeordnet wurden, mit benachbarten Clustern vereinigt oder Cluster verbunden, deren Mittelpunkte sehr dicht zusammen liegen (merge). Weiterhin können Klassen aufgeteilt werden, wenn sie eine sehr hohe Standardabweichung besitzen oder wenn sie sehr groß sind (DE LANGE, 2005).

Die Interpretation der Ergebnisse einer unüberwachten Klassifikation geschieht zumeist erst in Nachhinein. ALBERTZ (2007) gibt außerdem an, dass das unüberwachte Vorgehen häufig im Vorfeld einer überwachten Klassifikation geschieht, um zu prüfen, ob sich die gewünschten Klassen spektral trennen lassen oder in mehrere Unterklassen unterteilt werden müssen.

3.2.2 Vorgehen für den Ausschnitt Trier

Die Methode der unüberwachten Klassifizierung wurde für den Bildausschnitt von Trier nur für bestimmte, zuvor ausgewählte Bereiche genutzt. So zeigte sich im Rahmen der überwachten Klassifizierung (siehe Kapitel 3.1.2), dass sich insbesondere der Stadtbereich zu heterogen herausstellte, um über Trainingsgebiete erfasst werden zu können. Aus diesem Grund wurde für den Bereich, der auf dem Luftbild als Stadtbereich interpretiert wurde, ein weiteres Subset gebildet, welches in Abbildung 5 dargestellt ist. Für diesen Bildausschnitt wurde nun eine unüberwachte Klassifizierung mit 10 Klassen durchgeführt. Zudem wurden vor der Klassifikation Abbruchkriterien definiert. So wurden als maximale Anzahl der Iterationen 10 festgelegt, der 'convergence threshold', also der prozentuale Wert der Pixel, die pro Iteration noch verschoben werden, wurde auf 0,99 gesetzt. ERDAS IMAGINE nutzt für die unüberwachte Klassifikation den in Kapitel 3.2.1 beschriebenen ISODATA-Algorithmus.




Abbildung 5: Subset der potentiell als 'Stadt' zu klassifizierenden Bereiche

Aufgrund der zuvor erfolgten visuellen Auswahl der Stadtgebiete kann nun angenommen werden, dass die Signaturen aller 10 erhaltenen Klassen die Landnutzungsklasse 'Stadt' repräsentieren. Eine Zusammenführung mit den Signaturen aus der überwachten Klassifizierung sowie die Verwendung der Signaturen auf einen größeren Bildausschnitt ergab jedoch, dass es z. T. zu einer Fehlklassifizierung kam und einige der Klasse der unüberwachten Klassifikation nicht oder nur mit Einschränkungen zu verwenden waren (siehe Kapitel 3.3).

3.3 Ergebnis der hybriden Klassifizierung

Wie in Kapitel 3.1.2 und 3.2.2 beschrieben, wurden für die hybride Klassifizierung zunächst eine überwachte Klassifizierung mit den Trainingsgebiets-Daten für Wasser, Laubwald, Mischwald und Stadt durchgeführt. Da die als 'Stadt' vorgegebenen Gebiete zu heterogen waren, wurde dieser Bereich isoliert und unüberwacht klassifiziert. Von den so erhaltenen 10 zusätzlichen Klassen konnte nun angenommen werden, dass sie auf jeden Fall das Objekt 'Stadt' repräsentieren müssten. Im Anschluss wurden die Ergebnisse der ersten überwachten Klassifizierung und der unüberwachten Klassifizierung des Stadtgebietes zusammengeführt und der Bildausschnitt Trier erneut klassifiziert.

Eine Kontrolle des Ergebnisses ergab, dass das Stadtgebiet auf diese Weise in der Tat sehr gut erfasst werden konnte. Bei 5 Klassen der Nutzung 'Stadt' kam es zu einer Überschneidung mit anderen Klassen und somit zu einer Fehlklassifizierung im restlichen Bild. Diese wurden dementsprechend entfernt.

Bis zu diesem Zeitpunkt wurden durch die Klassifizierung die Landnutzungsklassen 'Ackerbau' und 'Grünland' noch nicht erfasst, da sie visuell nicht immer von einander zu unterscheiden waren, wenngleich sie sich durch ihre rechteckige Form zumeist recht deutlich von den übrigen Landnutzungsformen abhoben. Sie wurden also an dieser Stelle ebenfalls über AOIs extrahiert, wobei das Ergebnis der ersten vorläufigen Klassifizierung, in welcher die gesuchten Nutzungsklassen ja ebenfalls (falsch) klassifiziert wurden, sehr hilfreich bei der Unterscheidung von Grünland und Acker war.

Abbildung 6 zeigt den ERDAS Signature Editor, in welchem die gewonnenen spektralen Signaturen der einzelnen Objektklassen aus der überwachten und der unüberwachten Klassifizierung zusammengeführt wurden. Zudem wurden Signaturen, die zu einer Klasse gehören, derselbe Value gegeben, damit jede Landnutzungsklasse in der Attributtabelle des Ergebnisses (siehe Abbildung 16) nur einmal auftaucht. Insgesamt wurden 22 Klassen festgelegt, mit denen im Anschluss eine (überwachte) Gesamtklassifizierung durchgeführt wurde.

Signature Editor (signature-neu.sig)
 File Edit View Evaluate Feature Classify Help

Class #	>	Signature Name	Color	Red	Green	Blue	Value	Order	Count	Prob.	P	I	H	A	FS
1	>	Wasser1	Blue	0.000	0.000	1.000	1	1	124	1.000	X	X	X	X	
2		Wasser4	Blue	0.000	0.000	1.000	1	4	64	1.000	X	X	X	X	
3		Wasser7	Blue	0.000	0.000	1.000	1	7	45	1.000	X	X	X	X	
4		Wasser	Blue	0.000	0.000	1.000	1	8	104	1.000	X	X	X	X	
5		Nadelwald1	Green	0.000	0.392	0.000	2	9	525	1.000	X	X	X	X	
6		Laubwald1	Light Green	0.498	1.000	0.000	3	10	1000	1.000	X	X	X	X	
7		Laubwald	Light Green	0.498	1.000	0.000	3	11	1000	1.000	X	X	X	X	
8		Nadelwald	Dark Green	0.276	0.250	0.200	2	12	1000	1.000	X	X	X	X	
9		Acker1	Brown	0.824	0.706	0.549	4	13	88	1.000	X	X	X	X	
10		Acker	Brown	0.824	0.706	0.549	4	14	140	1.000	X	X	X	X	
11		Stadt1	Red	1.000	0.000	0.000	5	15	140	1.000	X	X	X		
12		Stadt2	Red	1.000	0.000	0.000	5	17	242	1.000	X	X	X		
13		Stadt4	Red	1.000	0.000	0.000	5	18	131	1.000	X	X	X		
14		Stadt	Red	1.000	0.000	0.000	5	19	153	1.000	X	X	X		
15		Ackerbau1	Orange	1.000	0.647	0.000	6	22	33	1.000	X	X	X	X	
16		Ackerbau2	Orange	1.000	0.647	0.000	6	23	115	1.000	X	X	X	X	
17		Ackerbau3	Orange	1.000	0.647	0.000	6	24	72	1.000	X	X	X	X	
18		Ackerbau	Orange	1.000	0.647	0.000	6	25	41	1.000	X	X	X	X	
19		Gruenland1	Cyan	0.498	1.000	0.831	7	26	56	1.000	X	X	X	X	
20		Gruenland2	Cyan	0.498	1.000	0.831	7	27	25	1.000	X	X	X	X	
21		Gruenland3	Cyan	0.498	1.000	0.831	7	28	19	1.000	X	X	X	X	
22		Gruenland	Cyan	0.498	1.000	0.831	7	29	36	1.000	X	X	X	X	

Abbildung 6: Signaturen der hybriden Klassifizierung




Abbildung 7: Ergebnis der hybriden Klassifizierung

Das Ergebnis der hybriden Klassifizierung ist der Abbildung 7 zu entnehmen. Insgesamt wurden 7 Landnutzungsklassen definiert. Die Evaluation und das Vorgehen zur weiteren Verbesserung des Ergebnisses werden im folgenden Kapitel 3.4 vorgestellt.

3.4 Ergebnisverbesserung

Um das Ergebnis der hybriden Klassifizierung bewerten zu können, bot es sich an, die spektralen Klassen im Feature Space darzustellen und gegebenenfalls zu optimieren. Dieses Vorgehen ist in Kapitel 3.4.1 beschrieben.

Bei der Auswertung des Ergebnisses ergaben sich einige Unregelmäßigkeiten durch ungewöhnliche Klassifizierungen. Diese zeigten sich insbesondere im rechten unteren Bildteil, wo vereinzelt die Klassen 'Ackerbau', 'Grünland' und auch 'Stadt' zu finden waren, welche jedoch nicht ihre typischen Formen zeigten und auch zu klein waren (siehe Abbildung 7). Da die Region an der Mosel und insbesondere auch um die Stadt Trier herum bekannt ist für ihren Weinbau, war anzunehmen, dass es sich um Weinbaugebiete handelt, welche durch die aktuellen Klassen nicht erfasst werden konnten. Da die Weinpflanzen nicht eine zusammenhängende Vegetation bilden und die Signaturen im Luftbild häufig den relativ kargen, flachgründigen und an vielen Stellen unbewachsenen Boden (laut MOSELWEIN E.V. (2010) handelt es sich größtenteils um Schieferhänge) der Weinbauflächen wiedergeben, ist es nicht möglich, allein auf Grundlage der spektralen Eigenschaften eine eigene Klasse ‚Wein‘ zu kategorisieren. Der Versuch, Trainingsgebiete an den Stellen zu setzen, an denen Wein visuell erkennbar war, ergab eine großflächige Fehlklassifizierung über das gesamte Bild (siehe Abbildung 8).

Wein wird bevorzugt an relativ steilen Hängen mit einer Ausrichtung nach Süden bis Südwesten (200 - 220 °) angepflanzt. Abhängig von der Exposition beschreibt BURMEISTER (2010) eine Hangneigung zwischen 18 und 58 % als optimal, um eine möglichst hohe Sonneneinstrahlung zu gewährleisten. Diese Angaben beziehen sich zwar auf die Weinbaugebiete des Rheins, es ist jedoch anzunehmen, dass die Exposition und die Hangneigung auf die Weine der Moselregion übertragbar sind. So gibt auch der MOSELWEIN E.V. (2010) aus Trier an, dass mittlerweile fast die Hälfte aller Weinbauflächen eine Hangneigung von über 30 % besitzen.




Abbildung 8: Fehlerhafte Klassifizierung des Ausschnittes Trier mit der Klasse 'Wein' (violett) nur anhand der spektralen Signatur

Um nun eine Klasse für die Landnutzungsclassen ‚Wein‘ ausweisen zu können, war es nötig, zusätzliche Informationen aus einem DEM in die Klassifizierung einfließen zu lassen. Dieses Vorgehen wird in Kapitel 3.4.2 beschrieben.

3.4.1 Feature Space

Der Feature Space, im deutschen auch Merkmalsraum genannt, ist ein n-dimensionaler Raum, der von n Kanälen aus einem Luftbild gebildet wird. Die Kanäle werden als $\lambda_1, \lambda_2, \lambda_3 \dots \lambda_n$ bezeichnet. Charakteristisch für die Messwerte einer Objektklasse ist, dass sich diese auf einen bestimmten Bereich des Feature Space konzentrieren (ALBERTZ, 2007). Ein Beispiel für solch ein Feature Space ist die Abbildung 4 aus Kapitel 3.2.1.

Auch unter ERDAS IMAGINE ist es möglich, ein sogenanntes Feature Space Image aus den Klassen eines Luftbildes zu erstellen. Hierbei werden 2 Kanäle ausgewählt und

gegeneinander aufgetragen, so dass man ein zweidimensionales Histogramm erhält. Für das Luftbild von Trier wurden für die Evaluation die Kombinationen aller Kanäle dargestellt und visuell ausgewertet. Beispielhaft ist in Abbildung 9 der Feature Space der Kanäle 3 und 4 dargestellt.




Abbildung 9: Feature Space für die Klassen der hybriden Klassifizierung

Die Werte der einzelnen Klassen werden durch die verschiedenfarbigen Kreise bzw. Ovale dargestellt. Die Farben entsprechen den Klassen, die in Abbildung 6 dargestellt sind. Konkret stehen die Farben für die Klassen Wasser (blau), Laubwald (hellgrün), Nadelwald (dunkelgrün), Acker bzw. Ackerbau (braun und orange), Stadt (rot) und Grünland (türkis). ALBERTZ (2007) stellt fest, dass die sich im Merkmalsraum für Messwerte mit einer hohen Korrelation typische ovale Formen bilden, während bei einer geringeren Korrelation die Klassen zumeist durch Kreise begrenzt werden.

Sehr deutlich hebt sich im Feature Space, wie erwartet, die Klasse ‚Wasser‘ im linken unteren Teil ab. Erfreulich ist, dass sich die Klasse ‚Stadt‘ im Feature Space ebenfalls deutlich hervorhebt, da diese zunächst zu heterogen war, um bei der überwachten Klassifizierung erfasst werden zu können. Durch die unüberwachte Klassifizierung unterscheidet sich ihre spektrale Signatur nun deutlich von den übrigen.

Auffällig ist, dass die Signaturen von Acker und Ackerbau im Feature Space deutlich getrennt sind. Dies deutet darauf hin, dass die Bereiche, die als ‚Acker‘ klassifiziert wurde, tatsächlich größtenteils brach liegen, während die Flächen, die als „Ackerbau“ kategorisiert wurden, zumindest teilweise von Vegetation bedeckt sind.

Die Abbildung des Feature Space zeigt weiterhin, dass sich die Klassen, die Vegetation beinhalten, teilweise überlappen. Für das spätere Gesamtergebnis wurden die Klassen mit einer zu starken Überschneidung eliminiert, so dass jede spektrale Klasse eindeutig definiert ist.

3.4.2 Nutzung des DEM im Spatial Modeler für die Bestimmung der Landnutzungs Klasse ‚Wein‘

Wie bereits geschildert, war es nicht möglich, die Landnutzungs Klasse Wein allein anhand ihrer spektralen Signatur festzulegen. Da die Region im Trier für seinen Weinbau bekannt ist und auch eine visuelle Auswertung des Luftbildes nicht wenige Weinbauflächen ergab, was zudem noch durch das Internetangebot von Google (Google Maps) bestätigt wurde, war es nötig, in die Klassifizierung zusätzliche Daten einzubringen.

Wein wird hauptsächlich an stark geneigten Hängen mit einer Süd- bis Südwest-Ausrichtung angebaut, um ein Optimum an Sonneneinstrahlung zu erreichen. Daher wurde für die Festlegung der Klasse Wein zusätzlich ein Digitales Höhenmodell verwendet.

In ERDAS IMAGINE besteht für die Luftbildauswertung die Möglichkeit, Expertenwissen einfließen zu lassen. Dies kann zum einen durch das Tool ‚Expert Classifier‘ geschehen. Es ermöglicht die regelbasierte Klassifizierung von multispektralen Bildern, die Verbesserung einer vorhandenen Klassifizierung oder auch GIS-Modelling. Der Expert Classifier geht nach

dem hierarchischen Verfahren der überwachten Klassifizierung vor. Man erhält einen sogenannten Entscheidungsbaum („decision tree“), der es ermöglicht, mit relativ wenigen feststehenden Informationen ein Maximum an Bildinformationen zu extrahieren. Der Expert Classifier setzt sich zusammen aus dem Knowledge Engineer, mit welchem die Bedingungen der Entscheidungsregeln definiert werden können, und dem Knowledge Classifier, über den auf die zuvor festgelegten Regeln zugegriffen werden kann, so dass eine Klassifikation auch von Nicht-Experten durchgeführt werden kann (ERDAS INC., 2001). Eine andere Methode, ein DEM in die Klassifizierung einzubinden, ist der Spatial Modeler von ERDAS IMAGINE. Dieses Tool erfordert nicht die Erstellung eines umfangreichen Entscheidungsbaumes sondern die Arbeitsschritte lassen sich relativ unkompliziert durch ein Modell umsetzen.




Abbildung 10: Schema des Spatial Modelers und des Expert Classifiers von ERDAS IMAGINE (ERDAS INC., 2008).

Die Schemata des Expert Classifiers und des Spatial Modelers sind in Abbildung 10 einander gegenübergestellt. Auch für die Verbesserung der hybriden Klassifizierung des Landsatbildes von Trier wurde der Spatial Modeler genutzt. Das entwickelte Modell ist in Abbildung 11 dargestellt.

Der Entscheidungsfindungsweg wird vereinfacht graphisch als Modell dargestellt. Dieses Interface wird auch als ‚Model Maker‘ bezeichnet. Die einzelnen Arbeitsschritte werden jedoch über die ‚Spatial Modeler Language‘ (SML) beschrieben. Hierbei handelt es sich um eine Skriptsprache, die für GIS-Modellierung und Bildbearbeitungsapplikationen entwickelt wurde (ERDAS INC., 2000). Ein Auszug aus dem Quelltext des Modells aus Abbildung 11 ist im Anhang beigefügt.




Abbildung 11: Mit dem Spatial Modeler umgesetzte Entscheidungsfindung für die Klasse 'Wein'

Zunächst wurden für den Bildausschnitt Trier zwei Bilder ermittelt, in denen die jeweilige Neigung in Prozent (PERCENT SLOPE) und die Ausrichtung in Grad (ASPECT) dargestellt werden. Im Menü des Spatial Modelers findet man unter der Kategorie ‚surface‘ sowohl die Funktion ‚percent slope‘, ebenso wie ‚degree slope‘, als auch die Funktion ‚aspect‘. Die Nutzung der beiden Funktionen werden im Spatial Modeler Reference Manual der Firma ERDAS INC. (2000) erläutert.

Die Berechnung der Neigung geschieht über den Befehl PERCENT SLOPE (<raster>, <units>) bzw. PERCENT SLOPE (<raster>, <xsize>, <ysize>). Der Ausgabewert ist abhängig vom Eingabewert <raster>. Es werden sowohl FLOAT- als auch INTEGER-Werte unterstützt, typischerweise handelt es sich um Höhenwerte. Bei dem Feature <unit> handelt es sich um den Datentyp STRING, <xsize> und <ysize> sind SCALAR. Die Berechnung der Hangneigung in Prozent ist eine Nachbarschaftsoperation und berechnet die Prozentwerte der Neigung in einer 3x3-Pixelnachbarschaft (ERDAS INC., 2000).

Die Ausrichtung einer Fläche ist über den Befehl ASPECT (<raster>), wobei es sich bei

<raster> ebenfalls um Höhenwerte handelt. Es werden die Datenformate FLOAT und INTEGER unterstützt, das Ergebnis ist ein Raster desselben Datenformates. Für jedes Pixel wird innerhalb einer 3x3-Nachbarschaft die Exposition berechnet. Der Ergebniswert 0 steht für ‚Nord‘ und steigt im Uhrzeigersinn an. Dementsprechend steht 90 für ‚Ost‘, 180 für ‚Süd‘ und 270 für ‚West‘ (ERDAS Inc., 2000).

Um nun die Bereiche herauszufiltern, in denen Wein angebaut werden könnte, wurden die beiden erhaltenen Raster zusammengeführt. Hierzu wurde die Funktion ‚EITHER <arg> IF (<test>) OR <arg2> OTHERWISE‘ genutzt. Diese ist unter dem Menüpunkt ‚Conditionals‘ zu finden. Es handelt sich um eine Punktoperation. Zunächst wird der Wert <test> in das Datenformat BINARY umgewandelt. Stellt sich <test> als ‚true‘ heraus, so wird <arg1> zurückgegeben, andernfalls <arg2>. Für <arg1> und <arg2> werden alle Datentypen unterstützt.

Für Weinbauggebiete wird eine gewisse Hangneigung erwartet, die an dieser Stelle mit minimal 19 % angenommen wurde. Die Ausrichtung ist generell Richtung Süden / Südwesten, seltener auch Richtung Südosten. Es wurde also angenommen, dass Weinbauggebiete einen Expositions-Wert zwischen 150 und 280 haben müssen. Über die Entscheidungsfunktion wurden nun alle Bereiche, auf die beide Merkmale gleichzeitig zutrafen, mit dem Wert 1 besetzt. Alle übrigen Bereiche bekamen den Wert 0.

Das Ergebnis dieses Modell-Schrittes ist in Abbildung 12 dargestellt.




Abbildung 12: Bereiche des Ausschnittes Trier mit einer Hangneigung > 19 % und einer Ausrichtung von Südost bis Südwest (weiß dargestellt)

Das so erhaltene Bild mit potentiellen Weinbaugebieten wurde nun für die „Entscheidungsfindung“ für das Gesamtergebnis verwendet. Ebenfalls über die Entscheidungsfunktion ‚EITHER <arg> IF (<test>) OR <arg2> OTHERWISE‘ wurde definiert, dass die Werte aus der Klassifizierung mit der Klasse ‚Wein‘ für die Bereiche übernommen werden sollten, die als Weinbaugebiet in Frage kommen, d.h., die durch die Verbindung von SLOPE und ASPECT den Wert ‚1‘ bekommen haben. Für alle übrigen Bereiche, d.h. für die Gebiete mit dem Wert ‚0‘, sollten die Werte der Klassifizierung ohne die Objektklasse ‚Wein‘ übernommen werden. Sowohl das Klassifizierungsergebnis mit als auch ohne den Wein wurde bereits dargestellt (Abbildung 8 und 7), in Abbildung 13 sind sie jedoch noch einmal vergleichend zu sehen.




Abbildung 13: Klassifizierung ohne (links) und mit (rechts) der Klasse 'Wein' (violett)

Zuletzt war es noch nötig, die Farben sowie die Klassenbezeichnung der ursprünglichen Klassifizierungen zu übernehmen.

3.4.3 Thresholding

Um das Ergebnis einer Klassifizierung in ERDAS IMAGINE zu evaluieren, bietet sich neben dem ‚Accuracy Assessment‘, bei dem das Ergebnis mit realen Werten verglichen wird, welche bei dieser Arbeit jedoch nicht vorlagen, auch das Verfahren des ‚Thresholdings‘ an. Bei diesem Vorgehen werden die Pixel identifiziert, welche mit hoher Wahrscheinlichkeit fehlerhaft klassifiziert wurden. Diese werden auf statistischem Wege anhand der euklidischen Entfernung des Pixels vom Mittelwert seiner Klasse im Merkmalsraum ermittelt. Während der Klassifizierung mit einer statistischen Methode wie dem Maximum-likelihood- oder dem Minimum-Distance-Verfahren kann eine sogenannte ‚distance image file‘ erstellt werden. In dieser sind die Werte enthalten, die sich für jedes Pixel einer Klasse aus einer

Gleichung ergeben, die von der gewählten Klassifizierungsmethode abhängt. Stellt man dieses Ergebnis nun als monochromes Rasterbild da, so ergibt sich, dass die helleren Pixel, also jene mit einem höheren ‚distance value‘, mit hoher Wahrscheinlichkeit nach falsch klassifiziert wurden, während dunklere Pixel wahrscheinlich korrekt sind. Die niedrigsten Grauwerte stammen in der Regel aus den Trainingsgebieten, sofern eine überwachte Klassifizierung durchgeführt wurde (ERDAS Inc., 1999). Das Histogramm solch eines ‚distance image files‘ ist in Abbildung 14 dargestellt.




Abbildung 14: Histogramm des distance image file (ERDAS Inc., 1999)

Das Histogramm zeigt keine Normalverteilung, sondern eine Chi-Quadrat-Verteilung. Solch eine Kurve ist das typische und erwartete Ergebnis eines distance image file.

Da die Pixelwerte mit der Entfernung vom Achsenschnittpunkt immer weniger wahrscheinlich zu einer Klasse gehören, definiert man nun einen Schwellwert („threshold“), ab welchem die Kurve „abgeschnitten“ wird und die Pixel nicht mehr zu dieser Klasse gehören. Der Schwellwert kann entweder mathematisch bestimmt oder visuell abgeschätzt und manuell gesetzt werden. Er wird häufig an der Stelle gesetzt, an der die Kurve merklich abflacht oder wenn nach dem Haupt-Peak noch (mehrere) kleinere folgen. Die so entfernten Pixel werden nun entweder eine bestehenden Klasse zugeordnet oder sie werden in eine neue Klasse verschoben bzw. bleiben unklassifiziert (ERDAS Inc., 1999).

Ursprünglich sollte auch die Klassifizierung des Luftbildausschnittes Trier auf diese Weise evaluiert werden. Auf diesen Schritt wurde jedoch aufgrund größerer technischer Schwierigkeiten letztendlich verzichtet.

4 Gesamtergebnis

Das Ergebnis der hybriden Klassifizierung mit den aus dem DEM gewonnenen Daten ist in Abbildung 15 zu sehen. Die Farben stehen wieder für Wasser (blau), Laubwald (hellgrün), Nadelwald (dunkelgrün), Acker (braun), Ackerbau (orange), Grünland (türkis) und Wein (violett). Um das Ergebnis bzw. seine Beschreibung übersichtlicher zu gestalten, wurden die spektralen Klassen in Landnutzungsklassen zusammengefasst (siehe Abbildung 16).





Abbildung 15: Ergebnis der hybriden Klassifizierung unter Einbezug des digitalen Höhenmodells



Row	Histogram	Color	Red	Green	Blue	Opacity	Class Names
0	0		0	0	0	0	Unclassified
1	3311		0	0	1	1	Wasser
2	22749		0.27	0.25	0.2	1	Nadelwald
3	110724		0.5	1	0	1	Laubwald
4	37944		0.82	0.71	0.55	1	Acker
5	24202		1	0	0	1	Stadt
6	56249		1	0.65	0	1	Ackerbau
7	9259		0.5	1	0.83	1	Gruenland

Abbildung 16: Attributtabelle des Ergebnisses mit den zusammengefassten Landnutzungsklassen

Es wird deutlich, dass die Landnutzungsklasse ‚Wein‘ nun weitaus kleinere Flächen einnimmt als bei der ersten Klassifizierung. Insbesondere im rechten unteren Teil wird dies deutlich. Ein Abgleich mit dem Luftbild (siehe Abbildung 1) sowie eine Überprüfung der als Wein klassifizierten Bereiche in Google Maps ergaben, dass die Weinbaugebiete äußerst gut getroffen wurden. So wurden durch die modifizierte Klassifizierung auch kleine Weinbaugebiete erfasst, die visuell nur schwer erkennbar waren.

Dennoch zeigen sich auch kleinere Schwächen. Da bei der ersten, rein spektralen Klassifizierung, sehr große Flächen als Wein kategorisiert wurden, wurden durch das Modell letztendlich auch Bereiche falsch als Wein klassifiziert. Deutlich wird dies vor allem im linken oberen Bildteil. Hier wurde unweit der A 64 eine relativ große Siedlungsfläche (wahrscheinlich der Ort Aach) zur Hälfte als Stadt und zur anderen Hälfte als Weinbaugebiet klassifiziert. Dieser Fehler ist wahrscheinlich auf eine relativ steile Hanglage des Ortes zurück zu führen, was auch in Google Maps durch die kurvige Straßenführung gestützt wird. Insgesamt zeigt sich, dass durch die Einbeziehung des DEMs zwar keine Weinbaugebiete mehr als Acker oder Grünland fehlklassifiziert werden, dass es aber immer noch zu einer falschen Einteilung der Weinbaugebiete in die Klasse Stadt kommt und umgekehrt. Dies lässt sich darauf zurückführen, dass zwar Ackerbau und Grünland in Hanglagen über 19 % praktisch nicht mehr vorkommen, dass durchaus aber Siedlungsbereiche an solchen Hängen gelegen sein können. Dieser Fehler lässt sich nur mit Hilfe des DEMs leider nicht korrigieren. Eventuell könnte die Bildung von mehr spektralen Klassen der Landnutzung ‚Wein‘ und ‚Stadt‘ eine Differenzierung erleichtern.

5 Zusammenfassung und Fazit

Durch das Vorgehen der hybriden Klassifizierung lassen sich die Vorteile der überwachten sowie der unüberwachten Klassifizierung miteinander verbinden. Dies wirkt sich vor allem darauf aus, dass der Bearbeiter durch die Nutzung der unüberwachten Klassifizierung frühzeitig erkennen kann, ob sich die von ihm gewünschten Objektklassen überhaupt spektral unterscheiden lassen. Die vorliegende Arbeit zeigte zudem, dass es so außerdem möglich ist, Objektklassen zu erfassen, die allein über eine überwachte Klassifizierung nicht differenzierbar wären. Allerdings war es hierfür nötig, zuvor Bereiche mit der gesuchten Landnutzung zu separieren, um dann nur diesen Ausschnitt zu klassifizieren.

Dementsprechend ist dieser Vorteil nur durch das manuelle Eingreifen des Bearbeiters nutzbar.

Weiterhin zeigte sich, dass das Ergebnis der Klassifizierung sich deutlich verbessern ließ, indem zusätzliche Informationen eingebunden wurden. So war es möglich, mit Hilfe eines DEMs Bereiche mit charakteristischen Standorteigenschaften für die Landnutzung 'Wein' zu filtern und bei einer abschließenden Klassifizierung diese Klasse nur an den Stellen auszuweisen, welche topographisch überhaupt geeignet sind.

Insgesamt lässt sich festhalten, dass das Verfahren der hybriden Klassifizierung das Endergebnis deutlich verbessert, dass jedoch auch auf diese Weise nicht jede Klasse nur anhand ihrer Signatur erfasst werden kann.

6 Quellen

ALBERTZ, J. (2007): Einführung in die Fernerkundung, Grundlagen der Interpretation von Luft- und Satellitenbildern, Wissenschaftliche Buchgesellschaft, 3. aktualisierte und erweiterte Auflage, Darmstadt

BURMEISTER, J. (2010): Mittelrhein-Weinführer, Die Topographie als terroirbestimmender Faktor, URL <<http://www.mittelrhein-weinfuehrer.de/Terroir.html>>, abgerufen am 09.03.2010

DE LANGE, N. (2005): Geoinformatik in Theorie und Praxis, Springer Verlag, 2. aktualisierte und erweiterte Auflage, Berlin Heidelberg New York

ERDAS INC. (1999): ERDAS Field Guide, Fifth Edition, Revised and Expanded, Atlanta Georgia, USA, abrufbar unter <<http://www.gis.usu.edu/manuals/labbook/erdas/manuals/FieldGuide.pdf>>, abgerufen am 25.03.2010

ERDAS INC. (2000): ERDAS IMAGINE Spatial Modeler Language Reference Manual, ERDAS IMAGINE V8.5, ERDAS Inc., Atlanta Georgia, USA, abrufbar unter <<http://www.gis.usu.edu/unix/imagene/SML.pdf>>, abgerufen am 21.03.2010

ERDAS INC. (2001): ERDAS IMAGINE Expert Classifier Overview, ERDAS Inc., Atlanta Georgia, USA, abrufbar unter <<http://www.gis.usu.edu/unix/imagene/ExpertClassifier.pdf>>, abgerufen am 21.03.2010

ERDAS INC. (2008): Course Details, Spatial Modeling & Expert Systems, URL <<http://gi.leica-geosystems.com/LGISub5x242x47.aspx>>, abgerufen am 21.03.2010

LEXIKON DER FERNERKUNDUNG (2009): Merkmalsraum, M-Lexikon der Fernerkundung, URL <<http://www.fe-lexikon.info/lexikon-m.htm#merkmalsextraktion>>, abgerufen 18.03.2010

MOSELWEIN E.V. (2010): Das Weinanbaugebiet Mosel, URL <<http://www.msr-wein.de/internet-de/broker.jsp?uMen=dd070a69-1ad6-f7f0-b529-61ef6c4fd7c7,12060a69-1ad6-f7f0-b529-61ef6c4fd7c7;0>>, abgerufen am 09.03.2010

PENGLER, I. (2007): Stadtstrukturentypenkartierung mit Methoden der Fernerkundung am Beispiel der Stadt Hyderabad (Indien), Diplomarbeit, Fachhochschule München, Fachbereich Geoinformationswesen, Studiengang: Kartographie und Geomedientechnik, Sommersemester 2007, abrufbar unter <www.shakti-project.org/app/download/.../Dipl-IsabellePengler-0707.pdf>, abgerufen am 18.03.2010

7 Anhang

Quelltext des Models (Auszug):

```
PAGESIZE 11.4, 8.66667 INCHES;
CELLSIZE MINIMUM;
WINDOW UNION;
PROJECTION DEFAULT;
AOI NONE;
OPTIMIZE NO;
RASTER {
    ID 1;
    TITLE "n1_dem";
    POSITION 1.42222, 0.833333;
    FILENAME "y:/06 msc09/s praxis dbv/14.1. hybride klassif/dem/dem.img";
    INTERPOLATION NEAREST;
    ATHEMATIC;
    DATATYPE FLOAT;
    DECLARE "Float";
    COMPRESSION UNCOMPRESSED;
    COORDINATES MAP;
    AOI NONE;
    RECODE NO;
    CHILD 2;
}
FUNCTION {
    ID 2;
    TITLE "PERCENT SLOPE ";
    POSITION 1.44445, 2.43333;
    VALUE "PERCENT SLOPE ( $n1_dem, \"meters\" ) ";
    AREA UNION;
    CHILD 3;
}
RASTER {
    ID 3;
    TITLE "n3_slope";
    POSITION 1.48889, 4.17778;
    FILENAME "y:/06 msc09/s praxis dbv/14.1. hybride klassif/dem/slope.img";
    DELETEDFILE;
    INTERPOLATION NEAREST;
    ATHEMATIC;
    DATATYPE UNSIGNED8;
    DECLARE "Integer";
    COMPRESSION UNCOMPRESSED;
    COORDINATES MAP;
    RECODE NO;
    CHILD 9;
}
FUNCTION {
    ID 7;
    TITLE "ASPECT ";
    POSITION 3.36666, 2.46666;
    VALUE "ASPECT ( $n6_dem ) ";
    AREA UNION;
    CHILD 8;
}
FUNCTION {
    ID 9;
    TITLE "EITHER 1 IF ";
    POSITION 2.51111, 5.85556;
    VALUE "EITHER 1 IF ( $n8_aspect>150 && $n8_aspect <280 && $n3_slope>19 ) OR 0 OTHERWISE
";
    AREA UNION;
    CHILD 10;
}
FUNCTION {
    ID 19;
    TITLE "EITHER $n18_trier_mit_wein IF ";
    POSITION 7.13333, 5.9;
    VALUE "EITHER $n18_trier_mit_wein IF ( $n10_south_slope==1 ) OR $n17_trier_test3
OTHERWISE ";
    AREA UNION;
    CHILD 20;
}
```