
5

5. *Klassifizierung*

5.1. Klassifizierung

Unter Klassifizierung versteht man die Zuweisung eines jeden Bildelements oder Bildsegments zu einer Klasse, deren Klassenbeschreibung die jeweilige Bildeinheit erfüllt. Jede Klasse wird durch spezifische Merkmale charakterisiert und dadurch von anderen Klassen unterschieden.

Jedes Bildelement wird auf alle Merkmale aller Klassenbeschreibungen untersucht und letztlich derjenigen Klasse zugeteilt, deren Eigenschaften es aufweist. Das Ziel jedes Klassifizierungsverfahrens ist es, die Gesamtheit der Bildelemente einer Szene in thematische Klassen oder Landnutzungsklassen einzuteilen.

Klassische Klassifizierungsmethoden, wie die *maximum-likelihood*, *minimum-distance* oder *parallelepiped classification* bedienen sich binärer Entscheidungsregeln bezüglich der Zugehörigkeit des Bildelementes zu einer Klasse. Sie bringen zum Ausdruck, ob das Element der Klasse gehört (=1) oder nicht (=0). Diese Klassifizierungsmethoden werden auch als harte Klassifizierungssysteme, *hard classifiers*, bezeichnet. Im Gegensatz zu ihnen benutzen die weichen Klassifizierungssysteme, *soft classifiers*, den Grad der Zugehörigkeit des bestimmten Bildelementes zu jeder in der Klassenhierarchie vorhandenen Klasse (*Fuzzy systems*), wobei der Zugehörigkeitsgrad nicht nur die binären Werte,

sondern auch Zwischenwerte annehmen kann. In diesem Fall bedeutet der Wert 1 die sichere Zugehörigkeit und der Wert 0 die sichere Nichtzugehörigkeit zu einer bestimmten Klasse. Der Vorteil der *soft classifiers* besteht in der Möglichkeit der Darstellung der Unsicherheiten bezüglich der Zugehörigkeit zu Klassen. Ein Bildobjekt kann mehreren Klassen mit unterschiedlicher Wahrscheinlichkeit zugeordnet werden.¹⁰³ Dieses Prinzip entspricht eher der menschlichen Zuordnung und der linguistischen Beschreibung der Objekte in der Welt als harte Regeln. Die Klassifikationsergebnisse der *soft classifiers* stehen dadurch dem menschlichen Erkennen viel näher.

Die gebräuchlichsten pixel-basierten Klassifikationsmethoden gehören zu den harten Klassifizierungssystemen. Das in dieser Arbeit verwendete objekt-basierte Verfahren basiert auf *Fuzzy systems*, die zu den weichen Klassifizierungssystemen zählen. Nachfolgend werden die zwei für Fernerkundung gängigsten Klassifizierungsverfahren – das pixel- und das objekt-basierte Verfahren – dargestellt.

¹⁰³ Baatz, M. et al. (2004).

5.2. Pixel-basierte Klassifizierung

Pixel-basierte Klassifizierung wird auch als Multispektralklassifizierung bezeichnet. Die zu klassifizierenden Einheiten sind die einzelnen Pixel. Normalerweise werden nur deren spektrale Eigenschaften verwendet, es wird also keine Kontextinformation berücksichtigt. Die einzelnen Pixel und deren Klassenzuweisung haben bei einfachen Verfahren keinen Einfluss auf die Klassifizierung der benachbarten Pixel. Die zu klassifizierenden Landnutzungsklassen unterscheiden sich durch spezifische Kombinationen der DN-Werte, die

ihren typischen Reflexionswerten entsprechen. Die pixel-basierten Klassifizierungen neigen zum *salt-and-pepper*-Effekt. In diesem Fall erscheint die klassifizierte Szene sehr heterogen. LILLESAND¹⁰⁴ unterscheidet drei Klassifizierungsverfahren: die überwachte (*supervised*-), die unüberwachte (*unsupervised*-) und die hybride Klassifizierung (*hybrid classification*). Hier und bei HILDEBRANDT¹⁰⁵ ist eine detaillierte Darstellung der drei Methoden sowie unterschiedlicher Klassifikationsalgorithmen zu finden.

¹⁰⁴ Lillesand, T. M. et al., (2004): Remote Sensing and Image Interpretation. 5. Aufl., (Ort?), Fifth Edition, New York, S. 551 f.

¹⁰⁵ Hildebrandt, G. (1996): Fernerkundung und Luftbildmessung für Forstwirtschaft, Vegetationskartierung und Landschaftsökologie., Heidelberg, S. 526 ff.

5.3. Objekt-basierte Klassifizierung

Wie im vorangegangenen Kapitel erläutert, stößt die isolierte Betrachtung des Pixels bei der Klassifizierung häufig an ihre Grenzen. Insbesondere bei der Klassifizierung der VHSR-Daten ist es notwendig, zusätzliche Informationen über die auszuwertende Szene einzubeziehen. Die objekt-orientierten Ansätze wurden schon früher im Bereich der digitalen Bildverarbeitung und der

pattern-recognition erfolgreich eingesetzt. Die Software *Definiens Professional* wurde im Jahre 2000 von der Firma *Definiens Imaging* als erste kommerzielle Software im Bereich der objekt-basierten Bildanalyse auf den Markt gebracht. Dadurch konnten seither die Vorteile der objekt-orientierten Bildanalyse auch für die Auswertung der Fernerkundungsdaten genutzt werden.

5.4. Klassifizierung mit *Definiens Developer*

In diesem Kapitel wird die Klassifizierung urbaner Räume beschrieben. Allgemein werden Klassifizierungsalgorithmen und Besonderheiten in *Definiens Developer* erläutert. Die Verwendbarkeit dieser Ansätze wird in Kapitel 6.7. untersucht. Ursprünglich wurden die

Klassifizierungen mit *Definiens Professional 5.0* begonnen. Da der Funktionsumfang bei *Definiens Developer* aber deutlich größer ist und vor allem eine komfortable Übertragung von Algorithmen erlaubt, wurde für die Klassifizierung dieser Wechsel vollzogen.

5.4.1. Fuzzy-Klassifizierung in *Definiens Professional 5.0*

Die Software *Definiens Professional* ermöglicht die Segmentierung der Bilddaten auf mehreren Maßstabsebenen. Der erste Schritt besteht darin, die Bildszene mithilfe des geeigneten Segmentierungsverfahrens unter Berücksichtigung bestimmter Homogenitätskriterien in sinnvolle, der realen Welt entsprechende Objekte einzuteilen. Die nachfolgende Klassifizierung der Segmente erfolgt wissensbasiert. Dieses Wissen wird genutzt, um Modelle und Regeln zu formulieren. In einer Klassenbeschreibung werden die charakteristischen Eigenschaften der Klassen benannt. In *Definiens Professional* bestehen zwei Möglichkeiten, die Klassifizierung durch-

zuführen: entweder durch die Definition von Trainingsgebieten (*Samples*), die dann mit *Nearest-Neighbor-Classifer* klassifiziert werden können, oder durch die *Fuzzy-Zugehörigkeitsfunktionen*, wobei die Objekte denjenigen Klassen zugewiesen werden, deren Klassenbeschreibungen sie am besten erfüllen. Bei objekt-orientierter Klassifizierung werden nicht die Informationen der einzelnen Pixel in die Auswertung einbezogen, sondern die der Objekte. Die Klassenbeschreibung, die Zugehörigkeitsfunktionen und Regeln für die Formulierung der Wissensbasis werden im folgenden Abschnitt detailliert dargestellt.

Fuzzy-Klassifizierung zählt zu den *soft-classifiers* und basiert auf der *Fuzzy-Logik*. Diese wird auch als unscharfe Logik“ bezeichnet und stellt eine Erweiterung der Booleschen Logik dar, die nur zwei Werte kennt: *falsch* und *wahr* oder 0 und 1. Die *Fuzzy-Logik* erlaubt auch die Verwendung von Zwischenwerten. Möglich wird dies durch die Ausdehnung des Wertebereichs der Booleschen Logik von $\{0; 1\}$ auf ein Intervall von $[0; 1]$, so dass ein Übergangsbereich von *falsch* nach *wahr* entsteht.¹⁰⁶ Dieser Übergangsbereich wird durch eine Zugehörigkeitsfunktion (*Fuzzyfunction*) definiert. Die *Fuzzy-Set-Theorie* – die unscharfe Mengenlehre – wurde bereits 1965 von L.A. ZADEH, Professor für Elektrotechnik an der University of California, Berkley, USA entwickelt. Laut ZADEH¹⁰⁷ wird jedem Element x in der Menge X ein bestimmter Grad der Zugehörigkeit zur Menge A zugeordnet:

$$A := \{(x, \mu_A(x)); x \in X\}$$

Ein Element kann auch ein wenig“ oder fast vollständig“ in der Grundmenge enthalten sein, wobei der Grad der Zugehörigkeit durch eine Zugehörigkeitsfunktion beschrieben wird. Diese Funktion weist den Elementen einer Grundmenge eine reelle Zahl zwischen 0 (keine Zugehörigkeit) und 1 (volle

Zugehörigkeit) zu. Dementsprechend können auch Werte wie z.B. 0,6 definiert werden.

$$\mu_A : X \rightarrow R$$

Eine *unscharfe Menge* ist die Menge aller Zugehörigkeitsfunktionen $\mu_A(x)$ in einem Definitionsbereich. Es können für die unscharfe Menge neben der Beschreibung aller Elemente auch unterschiedliche logische Operatoren wie *und*, *oder*, *nicht* oder *wenn* und *dann* zur Regelerstellung definiert werden.¹⁰⁸

Die *Fuzzy-Klassifizierungssysteme* können als eine Schnittstelle zwischen dem mit Unschärfe behafteten menschlichen Denken und dem Rechner bezeichnet werden. Sie helfen, die unscharfen Aussagen in mathematische Sprache umzusetzen. Demzufolge sind die *Fuzzy-Klassifizierungssysteme* im Stande, die Unsicherheiten und Verschwommenheiten zwischen Objektklassen in den Fernerkundungsdaten zufrieden stellend auszuwerten.

Die *Fuzzy-Klassifizierung* ist ein komplexer Vorgang, der aus drei Hauptschritten besteht: *Fuzzifizifikation*, *Fuzzy Rule Base* und *Defuzzifikation*.¹⁰⁹ Sie werden nachfolgend im Detail beschrieben.

¹⁰⁶ Weidner, U. u. Lemp, D. (2005).

¹⁰⁷ Zadeh, L. A. (1965): Fuzzy Sets.; In: Information and Control, 8. Jg. (1965), Nr .3, Academic Press, New York u. London, S. 338-353.

¹⁰⁸ Leukert, K. (2005), S. 16.

¹⁰⁹ Baatz, M. et al. (2004).

5.4.2. Fuzzy-Klassifizierung: Fuzzification

Fuzzifizierung beschreibt den Übergang von den harten zu den weichen Klassifizierungssystemen. Die Klassifizierung in Definiens Professional erfolgt anhand der Wissensbasis, die durch charakteristische Eigenschaften der Objektklassen mithilfe der *Fuzzy-Zugehörigkeitsfunktionen* in den Klassenbeschreibungen (*class description*) formuliert wird. Alle Objektklassen sind einer gewünschten Rangordnung nach in einer Klassenhierarchie enthalten. Die Klassenhierarchie kann als ein Rahmen für die Formulierung der Wissensbasis für eine bestimmte Klassifizierung verstanden werden. Sie enthält alle Klassen und ordnet sie einer gewünschten Rangordnung nach in einer Hierarchie. Diese Hierarchie wird in zwei Registerkarten *Inheritance* und *Groups* aufgebaut.

Die *Inheritance*-Registerkarte bezieht sich eher auf physikalische Zusammenhänge zwischen den Klassen. Hier werden alle in Elternklassen formulierten Merkmale an ihre Kinderklassen vererbt. Sobald eine Eigenschaft in der Elternklasse verändert wird, geschieht das auch automatisch in deren Kinderklassen. Die *Inheritance* ermöglicht es, die Komplexität und Redundanz in der Klassenhierarchie zu reduzieren und klare und übersichtliche Ordnung beizubehalten.

Die *Groups*-Registerkarte bezieht sich auf semantische Zusammenhänge der Klassen. Hier werden unterschiedliche Kinderklassen unter einer Elternklasse zusammengefasst, die in der semantischen Hierarchie ein Oberbegriff für diese Kinderklassen ist. Es können demzufolge Klassen mit sehr unterschiedlichen spektralen Eigen-

schaften semantisch zusammengefasst und unter einer Elternklasse auf andere Ebenen übertragen werden. Alle klassenbezogenen Merkmale beziehen sich auf die Klassen aus der *Groups* Registerkarte.

Die geordnete Struktur erlaubt die Vererbung der Eigenschaften von bestimmten Eltern- an ihre Kinderklassen oder auch das Gruppieren der gewünschten Klassen in semantische Klassengruppen.

So wie bei überwachter Klassifizierung die Trainingsgebiete die Klassen definieren sollen, so sind bei der objekt-orientierten Klassifizierung die Klassenbeschreibungen dafür verantwortlich. Für jede Objektklasse wird eine für sie typische Klassenbeschreibung erstellt. In diesen werden die Eigenschaften der jeweiligen Klasse mithilfe der Zugehörigkeitsfunktionen definiert. Eine Klassenbeschreibung muss manuell erstellt werden und kann aus mehreren Merkmalen bestehen. Als Grundregel gilt, „so wenige Merkmale, wie nötig“ in der Klassenbeschreibung zu verwenden. In die Klassenbeschreibungen können außer der spektralen auch weitere Eigenschaften einbezogen werden. Definiens Professional ¹¹⁰ stellt zahlreiche objekt-, sowie klassenbezogene Merkmale zur Erstellung der Wissensbasis zur Verfügung.

¹¹⁰ Ebd.

Objektmerkmale:

- *Layer values*: Eigenschaften der Pixel eines bestimmten Kanals, aus denen ein Objekt zusammengesetzt ist (spektrale Eigenschaften und deren Statistiken);
- *Shape*: geometrische Eigenschaften und Formeigenschaften der Objekte, u.a. Größe, Länge, Breite, Rundheit, Kompaktheit, Richtung;
- *Texture*: Texturmerkmale, die entweder auf den spektralen Eigenschaften oder den Formeigenschaften der Sub-Objekte oder auf der Berechnung der *Gray Level Co-Occurance Matrix (GLCM)* basieren;
- *Hierarchy*: Information über die Positionierung der Segmente auf einem bestimmten Segmentierungslevel;
- *Thematic attributes*: Thematische Attribute aus der zusätzlichen Layer, wie z.B. GIS-Daten.

Klassenbezogene Merkmale stellen Beziehungen zur Klassifizierung oder zu den Eigenschaften der räumlich benachbarten Objekte her und beschreiben z.B. das Verhältnis der Länge der Grenzen zu den Objekten einer bestimmten Klasse auf demselben *level*, die Existenz der

Objekte einer bestimmten Klasse auf dem größeren *level* oder das Verhältnis der relativen Fläche eines Objektes zur Fläche des Objekts auf dem feiner aufgelösten *level*. Die klassenbezogenen Merkmale können folgendermaßen gruppiert werden:

- Relations to neighbour objects
- Relations to sub-objects
- Relations to super-objects
- Membership to
- Classified as
- Classification value of

Es besteht außerdem die Möglichkeit, unter Verwendung der vorhandenen Eigenschaften neue zu generieren wie z.B. NDVI und andere Quotienten, die ein Verhältnis beschreiben.

Für die Qualität der Klassifizierung ist ausschlaggebend, dass die Merkmale und ihre Fuzzyfunktionen sorgfältig und durchdacht ausgewählt werden. Je eindeutiger das Wissen über die zu klassifizierende Szene mithilfe der Eigenschaften und Zugehörigkeitsfunktionen formuliert ist, desto zuverlässiger ist das Klassifizierungsergebnis. Zur Verfügung stehen sowohl Fuzzy-, als auch scharfe Zugehörigkeitsfunktionen. In Abb. 40 wird die Fuzzy-Zugehörigkeitsfunktion „größer als“ für das Merkmal „X“ dargestellt.

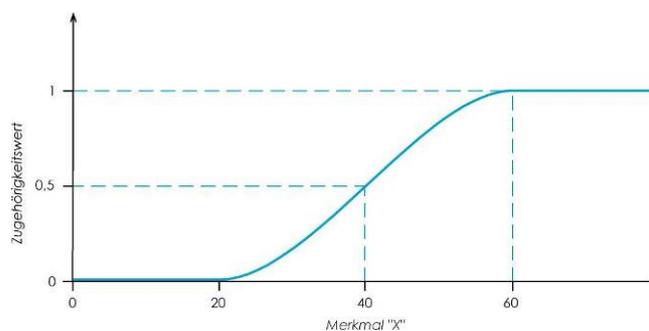


Abb. 40 Fuzzy-Zugehörigkeitsfunktion: „größer als“

Allen Segmenten mit einem mittleren Wert für das Merkmal „X“ größer als 60 wird der Zugehörigkeitswert 1 zugewiesen, d.h. die Segmente stimmen mit dem jeweiligen Merkmal aus der Klassenbeschreibung zu 100% überein, womit auch eine absolute Zuweisung zur Klasse gesichert ist. Alle Segmente, die dagegen für die Eigenschaft „X“ einen mittleren Wert

kleiner als 40 aufweisen, bekommen einen Zugehörigkeitswert von 0,5, was einer Zugehörigkeitswahrscheinlichkeit von 50% entspricht. Alle Segmente, die einen kleineren Wert als 20 besitzen, werden mit einem Zugehörigkeitswert 0 versehen, d.h. sie erfüllen die Klassenbeschreibung nicht und gehören daher keinesfalls zur Klasse.

5.4.3. Fuzzy-Klassifizierung: Fuzzy Rule Base

Fuzzy Rule Base ist eine Zusammensetzung aller Zugehörigkeitsfunktionen, die die Beschreibung einer Objektklasse ausmachen. Um die Objektklassen gut voneinander trennen zu können, müssen in der Regel mehrere Merkmale in der Klassenbeschreibung verwendet werden. In Abb. 41 ist diese Klassenbeschreibung durch mehrere Merkmale zu sehen. Für ein einzelnes Objekt wird während des Klassifizierungsprozesses ein Zugehörigkeits-

grad für jede in der Klassenbeschreibung enthaltene Eigenschaft berechnet. Wenn die Klassenbeschreibung aus drei Merkmalen besteht, werden für das Objekt drei Zugehörigkeitsgrade berechnet. Um nur eine Zahl daraus zu ermitteln, werden die Merkmale mit unterschiedlichen *Fuzzy-Operatoren* miteinander verbunden. Die Auswahl der Operatoren beeinflusst den endgültigen Zugehörigkeitswert des Objektes zur jeweiligen Klasse.

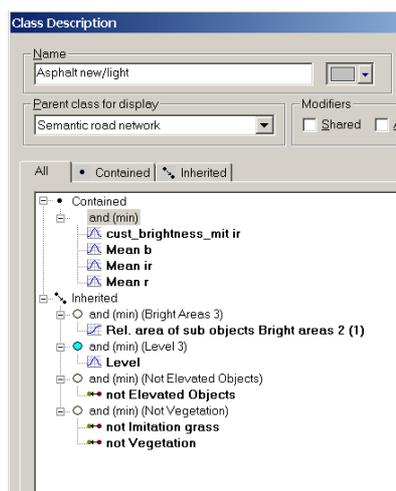


Abb. 41 Merkmalsbeschreibung für eine Klasse

Es gibt folgende vordefinierte *Fuzzy-Operatoren* zur Ermittlung des endgültigen Zugehörigkeitswertes:¹¹¹

- and (min): der Kleinste aller Zugehörigkeitswerte,
- and (*): das Produkt aller Zugehörigkeitswerte,
- or (max): der größte aller Zugehörigkeitswerte,
- mean (arithm.): arithmetisches Mittel aller Zugehörigkeitswerte,
- mean (geo): geometrisches Mittel aller Zugehörigkeitswerte.

Ein großer Vorteil der *Fuzzy-Klassifizierung* besteht darin, dass jedes Objekt einen Zugehörigkeitsgrad für jede in der Klassenhierarchie vorhandene Landnutzungs-kategorie besitzt. Ein Objekt kann mehreren Klassen zu einem unterschiedlichen Grad angehören.

In Abb. 42 wird das Klassifizierungsergebnis eines Objektes für drei Klassen dargestellt. Im Allgemeinen gilt: Je mehr sich der Zugehörig

keitsgrad für die beste Klasse vom Zugehörigkeitsgrad zur zweitbesten und zu den übrigen Klassen unterscheidet, desto stabiler ist die Trennung der Klassen und desto zuverlässiger ist die Gesamtklassifikation.¹¹² Im Fall a) gehört das Objekt drei Klassen an, aber in ungleichem Grad. Weil der Unterschied zwischen den Zugehörigkeitsgraden der zwei besten Klassifizierungen relativ groß ist, bleibt die Klassenzuweisung stabil. In den Fällen b) und c) lassen gleiche Zugehörigkeitszahlen erkennen, dass die Klassenzuweisung für das betroffene Objekt instabil ist. Im Fall c) wird die Klassifizierung zusätzlich wegen des geringen Zugehörigkeitsgrades zu allen vorhandenen Klassen sehr unzuverlässig.

Die Fuzzy-Klassifizierung kann auf alle Fernerkundungsdaten angewandt werden. Sie gilt als sehr zuverlässig bei der Ermittlung der Wahrscheinlichkeiten für Klassenzuweisungen, und zwar sowohl für die beste als auch für die zweitbeste Klasse, der das jeweilige Objekt zugeordnet wird.

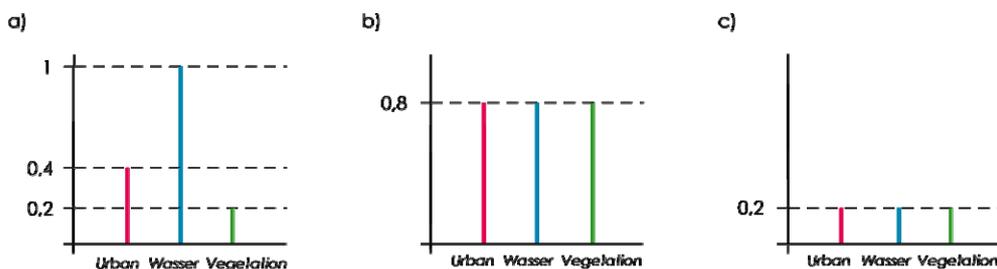


Abb. 42 Fuzzy-Klassifizierung eines Objektes für vorhandene Klasse (verändert nach *eCognition User Guide, 2004*)

¹¹¹ Baatz, M. et al. (2004), S. 95 f.

¹¹² Baatz, M. et al. (2004), S. 71 ff.

5.4.4. Fuzzy-Klassifizierung: Defuzzification

Die Ergebnisse der *Fuzzy-Klassifizierung*, die die Zugehörigkeit eines Objektes zu mehreren Klassen erlaubt, müssen wieder in eindeutige Klassen überführt werden, damit die Ergebnisse in sinnvoller Form in einer Karte oder einem GIS weiterverarbeitet werden können.

Einem Objekt wird diejenige Klasse zugewiesen, zu der es den höchsten

Zugehörigkeitsgrad aufweist. Das in Abb. 42 mit a) bezeichnete Objekt wäre der Klasse „Wasser“ zugeordnet worden. Für diese Zuordnung kann ein Schwellenwert definiert werden.

Diesen Übergang von der Fuzzy- in die Boolesche Logik nennt man *Defuzzification*.¹¹³ Das Ergebnis dieses Prozesses ist eine eindeutige Zuordnung eines jeden Objekts in genau eine Klasse.

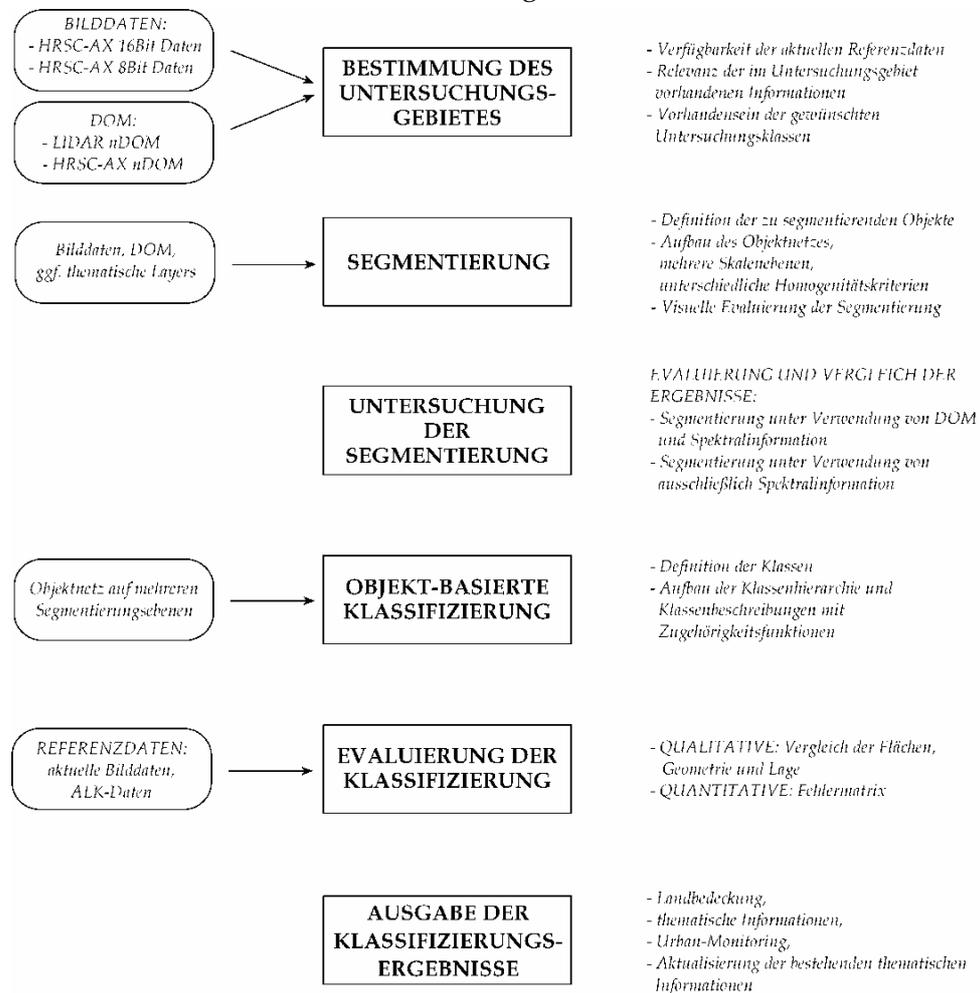


Abb. 43 Workflow der objekt-basierten Klassifizierung

¹¹³ Baatz, M. et al. (2004), S. 69 ff.

5.5. Evaluierung der Klassifizierungsgüte

Die Beurteilung eines Klassifizierungsergebnisses ist wichtig, um zu entscheiden, ob die erreichte Qualität ausreicht oder nicht. Zusätzlich ermöglicht sie dem Anwender, Schwachstellen zu erkennen und die Klassifizierung so zu verbessern. Die Beurteilung der Klassifikationsgenauigkeit kann einen *qualitativen* oder einen *quantitativen* Charakter haben.

Das Ziel der *quantitativen* Beurteilung ist die Identifizierung der Fehler in der Analyse. Die Grundvoraussetzung für jede *quantitative* Beurteilung ist die Verfügbarkeit der Referenzdaten (*Ground Truth*), die im Idealfall sehr genau sein und zeitnah zu den Fernerkundungsdaten erhoben werden sollten. Diese Forderung ist jedoch nur eingeschränkt realisierbar, da genaue und zuverlässige Referenzdaten selten zur Verfügung stehen.

Die Klassifizierungsgenauigkeit von 85% wird im Allgemeinen als Grenze zwischen einem akzeptablen und einem inakzeptablen Ergebnis angenommen. Die Zuverlässigkeit der Genauigkeitsüberprüfung hängt jedoch von mehreren Faktoren ab. Die Quelle der Referenzdaten, die Methode mit der diese aufgenommen wurden (Stichprobenverfahren und Größe der Stichprobe), ihre Genauigkeit und Aktualität sowie das Klassifikationschema (Anzahl der Klassen, Klassenbeschreibung, Klassifikationsalgorithmus) sind für die Klassifikationsevaluierung ausschlaggebend. Sie entscheiden über die

Zuverlässigkeit der Klassifikation. CONGALTON und GREEN¹¹⁴ weisen darauf hin, dass die Grenze von 85% für manche Anwendungen für genau genug, für andere aber für zu ungenau gehalten wird. Ein sehr oft angewandtes Schema für die Beurteilung der Übereinstimmung von Klassifizierungsergebnissen und Referenzdaten wurde durch LANDIS und KOCH¹¹⁵ erstellt. Die drei besten Kategorien werden folgendermaßen definiert:

- almost perfect: 0,81 – 1
- substantial: 0,61 – 0,8
- moderate: 0,41 – 0,6

Im Folgenden werden die Evaluierungsmethoden für die pixel- und objekt-basierte Klassifizierung dargestellt. Darüber hinaus werden die Probleme bei der Verifizierung der Klassifizierungsgüte der VHSR-Daten kurz geschildert.

¹¹⁴ Congalton, R. G. u. Green, K. (1999): Assessing the Accuracy of Remotely Sensed Data: Principles and Practices., Lewis Publishers, Boca Raton, S. 45.

¹¹⁵ Landis, J. R. u. Koch, G. G. (1977): The Measurement of Observer Agreement for Categorical Data. In: Biometrics, 3. Jg., S. 159-174.

5.6. Evaluierungsmethoden für Klassifizierungsansätze

Die folgenden Kapitel stellen unterschiedliche Methoden zur Bewertung der Klassifizierungsergebnisse dar. Als erste werden die Verfahren zur Evaluierung der pixelbasierten und nachfolgend die zur Evaluierung der objektbasierten Klassifizierung beschrieben. An dieser Stelle ist zu bemerken, dass sich die Beurteilungsmethoden der pixel-

basierten Klassifizierung auch als Standardverfahren zur Evaluierung der objektbasierten Ansätze etabliert haben, weil bis jetzt noch keine expliziten Verfahren für objektbasierte Klassifizierungen entwickelt wurden. Als Methoden zur Evaluierung von objektbasierten Klassifizierungen bieten sich die Methoden der pixelbasierten Verfahren an.

5.6.1. Evaluierung der pixelbasierten Klassifizierungsansätze

Als Methoden zur Evaluierung von objektbasierten Klassifizierungen bieten sich die gut dokumentierten Methoden der pixelbasierten Verfahren an.

Eine der am meisten eingesetzten Methoden für die Beurteilung der Klassifizierungsergebnisse der pixelbasierten Ansätze ist die *Fehlermatrix*, auch *Konfusions-* oder *error matrix* genannt. Die Fehlermatrix ist ein tabellarischer Vergleich der Referenzdaten mit den korrespondierenden Ergebnissen der Klassifizierung. Für jede Klasse wird angegeben, wie viele der betrachteten Pixels (Cluster oder Polygone) korrekt oder falsch klassifiziert wurden. Im vorliegenden Fall bezieht sich die Evaluierung auf die Referenzdaten

und betrachtet sie dementsprechend als fehlerfrei.¹¹⁶ In Tab. 10 wird die mathematische Darstellung der Konfusionsmatrix gezeigt.

Referenz Klassifizierung	1	2	k	Zeilen- Summe n_{j+}
1	n_{11}	n_{12}	n_{1k}	n_{1+}
2	n_{21}	n_{22}	n_{2k}	n_{2+}
k	n_{k1}	n_{k2}	n_{kk}	n_{3+}
Spalten- Summe n_{+j}	n_{+1}	n_{+2}	n_{+k}	N

Tab. 10 Mathematische Darstellung einer Konfusionsmatrix (nach Congalton u. Green¹¹⁷)

¹¹⁶ Congalton, R. G. u. Green, K. (1999), S. 45.

¹¹⁷ Ebd.

Referenz	Wasser	Urban	Wald	Getreide	Zeilensumme
Klassifizierung					
Wasser	65	4	22	24	115
Urban	6	81	5	8	100
Wald	0	11	85	19	115
Getreide	4	7	3	90	104
Spaltensumme	75	103	115	141	434

Tab. 11 Beispiel einer Konfusionsmatrix (nach Congalton u. Green¹¹⁸)

Die Zeilen der Matrix repräsentieren die Aufteilung der Ergebnispixel nach der Klassifizierung, während die Spalten die Pixel der Referenzdaten anzeigen. Die Anzahl der Referenzpixel richtet sich nach der Anzahl der klassifizierten Pixel. Pro Landnutzungs-kategorie sollten jedoch wenigstens 50 Referenzpixel vorhanden sein.

Aus der Fehlermatrix können mehrere statistische Werte über die Güte der Klassifizierung abgelesen werden. Um diese Maße besser verstehen zu können, wurde eine beispielhafte Konfusionsmatrix in Tab. 11 dargestellt.

Das Aufzeigen von so genannten Überlassungs- (*commission Error*) und Unterlassungsfehlern (*omission Error*) der Klassifizierung ist möglich.¹¹⁹ Diese Maße ermöglichen das Aufzeigen der Fehlerquellen, bzw. das Identifizieren instabiler Klassen. Die Hauptdiagonale der Tabelle repräsentiert die Referenzpixel, die richtig

klassifiziert wurden. Die nichtdiagonalen Elemente der Tabelle stellen die Über- oder Unterlassungsfehler dar.

Der *Unterlassungsfehler* wird in Spalten abgelesen. In Tab. 11 ist zu sehen, dass insgesamt 10 Pixel, die laut der Referenzdaten als *Wasser* klassifiziert werden sollten, aus der Klasse ausgeschlossen und den Klassen *Urban* und *Getreide* zugewiesen wurden.

Der *Überlassungsfehler* ist in den Zeilen zu finden. Er beschreibt, wie viele Pixel der anderen Klassen in der jeweiligen Ergebniskategorie vorkommen. Aus Tab. 11 ist ersichtlich, dass 11 *Urban*- und 19 *Getreide*-Referenzpixel fehlerhaft als *Wald* klassifiziert wurden.

Aus der Konfusionsmatrix lassen sich weitere Evaluierungsmaße wie die Gesamt-genauigkeit (*Overall Accuracy - O_A*), die Herstellergenauigkeit (*Producer's Accuracy - P_A*), die Nutzergenauigkeit (*User's Accuracy - U_A*) sowie der Kappa-Koeffizient (*Kappa Index*) ableiten. Definitionen und Formeln für diese Maße wurden aus CONGALTON und GREEN¹²⁰ entnommen.

¹¹⁸ Congalton, R. G., Green, K. (1999), *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*, Lewis Publishers, Boca Raton, S. 46.

¹¹⁹ Lillesand, T. M. et al. (2004), S. 586 f.

¹²⁰ Congalton, R. G., Green, K. (1999), S. 46 ff.

Der Buchstabe „ j “ steht für die Referenzklassen, der Buchstabe „ i “ für die Ergebnisklasse.

Die *Gesamtgenauigkeit* (O_A) wird aus der Summe aller korrekt klassifizierten

Pixel, hier durch die Hauptdiagonale der Matrix dargestellt, dividiert durch die Gesamtsumme n aller Pixel ermittelt.

$$O_A = \frac{\sum_{i=1}^k n_{ii}}{n}$$

n_{ii} = Elemente der Hauptdiagonalen
 k = Anzahl der Klassen
 n = Anzahl der Referenzpixel

Die O_A aus Tab. 11 beträgt 0,74.

Die Berechnung der *Overall Accuracy* liefert die Anzahl der richtig klassifizierten Pixel, jedoch keinerlei Informationen über die Qualität der einzelnen Klassen. Deren alleinige Berechnung ist aus diesem Grund ungenügend. Für eine detaillierte Qualitätsevaluierung der einzelnen Objektklassen werden weitere Maße aus der Konfusionsmatrix ermittelt.

Die *Herstellergenauigkeit* (P_A) berechnet das Verhältnis der korrekt klassifizierten Pixel (eine Zahl aus der Hauptdiagonale) zu der Gesamtzahl der Referenzpixel der jeweiligen Referenzklasse (Spaltensumme der jeweiligen Referenzklasse) und liefert damit ein Maß dafür, wie gut die Klassifizierung des Herstellers mit den Referenzdaten übereinstimmt.

$$P_A = \frac{n_{jj}}{n_{+j}}$$

n_{jj} = korrekt zur Klasse j zugewiesene Pixel
 n_{+j} = Gesamtanzahl der Referenzpixel der Klasse j

Die *Nutzergenauigkeit* (U_A) beschreibt das Verhältnis der korrekt zugeordneten Pixel (eine Zahl aus der Hauptdiagonale) zu der Gesamtzahl der Ergebnispixel der jeweiligen Klasse.

Sie ist ein Maß für die Wahrscheinlichkeit, mit der ein Ergebnispixel derselben Klasse in Referenzdaten angehört.

$$U_A = \frac{n_{ii}}{n_{i+}}$$

n_{ii} = korrekt zur Klasse i zugeordnete Pixel
 n_{i+} = Gesamtanzahl der Ergebnispixel der Klasse i

In der Regel werden die Maße für O_A , P_A und U_A als proportionaler Anteil in Prozent dargestellt. Berechnet man die Werte der P_A und U_A für die Klasse *Wasser* aus Tab. 11, betragen sie 0,87 und 0,56. Das heißt, dass obwohl 87% der *Wasser*-Referenzpixel richtig klassifiziert wurden, nur 56% der

Flächen, die auf der Ergebniskarte als *Wasser* dargestellt werden, in der Wirklichkeit den Wasserflächen entsprechen. Die U_A liefert also eine wichtige Information darüber, wie sicher ein als Klasse i klassifiziertes Pixel der gleichen Klasse in Referenzdaten entspricht.

Bei der Berechnung dieser Maße darf man nicht vergessen, dass sie nur erkennen lassen, wie stabil die Klassenbeschreibung ist und zwischen welchen Objektklassen eventuell eine Konfusion besteht.

Kappa-Koeffizient (KK; \hat{k})

Aus der Fehlermatrix lässt sich eine weitere Maßzahl für die Beurteilung der Gesamtgenauigkeit ableiten, nämlich der *Kappa-Koeffizient*, auch *Kappa-Index* genannt. Der KK verfolgt jedoch eine andere Idee als die *Overall Accuracy*. Die O_A ergibt die Anzahl der korrekt klassifizierten Pixeln unter der Annahme, dass die Referenzdaten

fehlerfrei sind. Der KK geht dagegen davon aus, dass die beiden Klassifizierungen – die erstellte und die Referenzklassifizierung – von gleicher Zuverlässigkeit sind. Wie gut sie miteinander übereinstimmen, ist das Untersuchungsthema des KK. Sein Vorteil gegenüber der O_A ist die Berücksichtigung der Unter- und Überlassungsfehler. Der KK korrigiert die Werte hinsichtlich der Zufalls-Übereinstimmung (*chance agreement*), die er bei den Berechnungen in Betracht zieht. Die Zufalls-Übereinstimmung bedeutet hier die Wahrscheinlichkeit, mit der die beiden Klassifizierungen übereinstimmen.¹²¹

$$KK = (\text{observed accuracy} - \text{chance agreement}) / (1 - \text{chance agreement})$$

Der KK berechnet sich aus der Differenz zwischen den korrekt klassifizierten Pixeln (Hauptdiagonale der Fehlermatrix) und einer inkorrekten Übereinstimmung, die durch die Zeilen- und Spaltensummen gegeben ist. Diese Differenz ist der Anteil der über den Zufall hinausgehenden Übereinstimmungen.

Damit wird berücksichtigt, dass auch bei einer willkürlichen Klassifizierung einige Pixel mit den Referenzdaten übereinstimmen können. Die ermittelte Differenz wird durch den theoretisch möglichen Anteil der über den Zufall hinausgehenden Übereinstimmungen dividiert.¹²² Der *Kappa-Koeffizient* wird folgendermaßen definiert:

¹²¹ Congalton, R. G. u. Green, K. (1999), S. 49 ff.

¹²² Tomowski, D. et al. (2006), Objektorientierte Klassifikation von Siedlungsflächen durch multisensorale Fernerkundungsdaten. In: Gi-reports@igf, Band 3, Universität Osnabrück. Online unter: http://elib.ub.uni-osnabrueck.de/publications/ELibD131_gi-reports_igf3.pdf

$$KK = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} n_{+i}}$$

$k = \text{Anzahl der Klassen}$
 $n = \text{Anzahl der Referenzpixel}$

Der KK kann Werte in einem Intervall von -1 bis 1 annehmen, wobei der Wert 1 eine völlige Übereinstimmung zwischen der Klassifizierung und den Referenzdaten bedeutet. Bei gleichen Anteilen der korrekten und inkorrekten Übereinstimmung beträgt demzufolge der $Kappa$ -Wert null.

Die Konfusionsmatrix hat sich bei der Beurteilung der Klassifizierungsgüte als Standardverfahren etabliert. Es ist jedoch zu bemerken, dass man bei ihrer Berechnung eine Anzahl von Einflussfaktoren in Betracht ziehen muss. Die Güte jeglicher

Qualitätsmaße hängt von der Güte der Referenzinformationen ab. Weil die Konfusionsmatrix auf der Annahme basiert, dass die Referenzdaten fehlerfrei sind, muss man deren Qualität und Aktualität besondere Beachtung schenken. Bei der Evaluierung muss außerdem der Zweck und der Detailgrad der Klassifizierung beachtet werden. Ein einzelner falsch klassifizierter Pixel könnte bei der Entwicklung einer Landnutzungskarte vernachlässigt werden, während derselbe Fehler bei anderen Anwendungen inakzeptabel wäre.

5.6.2. Evaluierungsmethoden der objekt-basierten Klassifizierungsansätze

Die oben beschriebenen Evaluierungsmethoden für die pixel-basierten Klassifizierungsverfahren werden in der Regel auch für die objekt-basierten Ansätze verwandt. Es werden jedoch nur die einzelnen Pixel in die Evaluierung einbezogen. Die Objektinformation bleibt unberücksichtigt.

Eine Möglichkeit bietet die Einbeziehung einiger Objektmerkmale zur qualitativen Beurteilung der Klassifizierung wie z.B. die Anzahl der Objekte, deren Größe oder Lage. Der Einsatz von solchen qualitativen Beurteilungsmaßen setzt aber eine qualitativ sehr genaue und den Referenzdaten geometrisch entsprechende Segmentierung voraus. Ein nennenswertes Beispiel ist die Abgrenzung der einzelnen Häuser bei Gebäudekomplexen oder bei einer dichten Bebauung in der ALK. Die

Segmentgrenzen solcher zusammengesetzter Bauten entsprechen selten denen aus den ALK-Daten. Damit stimmen Merkmale wie Anzahl und Größe der Gebäude nicht überein. Derartige Daten müssen erst aufbereitet werden, um einen sinnvollen Vergleich überhaupt zu ermöglichen.

Zu der Problematik, dass die ALK auf Grundrissen basiert, also auf einem Element, das aus der Luft nicht beobachtet werden kann, kommt das Problem, dass Abgrenzungen aller Art nicht den natürlichen Grenzen entsprechen. Außerdem ist die Berücksichtigung von geometrischen Merkmalen eher für anthropogene Objekte geeignet, da bei natürlichen Objekten wie Feldern, Wiesen oder Parks die eindeutige Abgrenzung nur eingeschränkt möglich ist. Der Unterschied zwischen anthropogenen

und natürlichen Objekten ist in einer Welt, in der der Mensch weite Bereiche seit Jahrhunderten bewirtschaftet, kaum mehr möglich; in der Regel finden wir in Europa eine Mischung aus beidem vor. Es ist beispielsweise schwer möglich, die Grenze zwischen Wald und Wiese genau zu definieren.

Ein zusätzliches Hindernis bei der qualitativen Evaluierung der Klassifizierung bildet das untersuchte Gebiet - in diesem Falle eine sich ständig entwickelnde und verändernde Metropole, für die aktuelle Referenzdaten oft nur in beschränktem Maße zur Verfügung stehen. Die Befliegungsdaten sind in der Regel aktueller als die vorhandenen Referenzdaten.

Auflösung und Bittiefe der zu klassifizierenden Daten bleiben auch nicht ohne Einfluss auf die Qualität der Segmente. Je höher Auflösung und

Bittiefe, umso schwieriger ist es, homogene Objekte zu segmentieren. Dies trifft besonders bei heterogenen Daten zu, wie z.B. bei Bilddaten der urbanen Räume. Oft kommt es vor, dass Häuser aufgrund sehr heterogener Dachflächen aus mehreren Segmenten bestehen, was wiederum die Evaluierung mittels der Qualitätsmerkmale einschränkt.

Zurzeit mangelt es an Methoden zur Beurteilung der objekt-basierten Klassifizierungen. Jedoch ist es aufgrund des Umgangs mit Zugehörigkeitsgraden bei der Fuzzy-Klassifizierung möglich, die Fähigkeit der erstellten Regelbasis zur Klassifizierung der gewünschten Objekte zu beurteilen. Außerdem stellt Definiens Professional ein Spektrum an statistischen Berechnungen zur Identifizierung und Auswertung der Ambiguitäten bei der Klassen-zuweisung bereit.¹²³

5.6.3. Genauigkeitseinschätzung unter Definiens Developer

Classification Stability

Der Fuzzy-Klassifizierung entsprechend können die klassifizierten Objekte einen Zugehörigkeitsgrad zu mehr als einer Klasse erhalten, siehe auch Kap.5.4.3. Das *Classification Stability* Werkzeug ermöglicht es, die Differenzen zwischen der besten und der zweitbesten Klassifizierung jedes einzelnen Objektes festzustellen. Das Evaluierungsergebnis wird in einer Tabelle dargestellt, die die statistischen

Größen, wie die Anzahl der Objekte, den Mittelwert, die Standardabweichung sowie der minimale und maximale Wert einer bestimmten Klasse darstellt. Die Evaluierungsmethode ermöglicht es die eventuellen Ambiguitäten in der Klassenzuweisung oder die Schwächen in der Klassenbeschreibung zu identifizieren.

¹²³ Baatz, M. et al. (2004), S. 291 ff.

Best Classification Result

Das *Best Classification Result*-Werkzeug lässt das beste Klassifizierungsergebnis jeder Klasse eines bestimmten *levels* darstellen. Als das beste Klassifizierungsergebnis wird der höchste aller Zugehörigkeitsgrade eines Objektes verstanden. Als Output wird eine Tabelle mit statistischen Größen der Anzahl der Objekte, den

Mittelwert, der Standardabweichung, den minimalen und maximalen Werte dargestellt. Mit dieser Evaluierungsmethode ist es möglich zu bewerten, inwieweit die Objekte, die für eine bestimmte Klasse den größten Zugehörigkeitsgrad aufweisen, die Klassenbeschreibung dieser Klasse erfüllen.

Error Matrix based on TTA-Mask

Die hier verwendete Error Matrix stellt gleiche statistische Berechnungen dar, wie die Fehlermatrix in Kap.5.6.1. Als Referenz benutzt sie die so genannte TTA-Mask. Diese Maske wird aus den Test- und Trainingsgebieten zusammengestellt. Die TTA-Mask kann in einer anderen Software erstellt und nach

Definiens `Developer` importiert werden. Der statistische Output wird in Form einer Konfusionsmatrix dargestellt. Auf weitere Darstellung der Matrix wird an dieser Stelle verzichtet, da sie schon in dem oben genannten Kapitel in allen Einzelheiten beschrieben wurde.

Error Matrix based on Samples

Diese Fehlermatrix ist der aus dem vorherigen Kapitel gleich. Sie benutzt aber als Referenz die für bestimmte

Klassen manuell gesammelten Samples - also nicht einzelne Pixel, sondern die aus mehreren Pixel bestehende Objekte.

Neueste Ansätze: Fuzzy Certainty Measurement-FCM

Unter der Annahme, dass die Klassifizierungsmodelle identisch sind und es keine Ungenauigkeiten aufgrund verschiedener Pixelgrößen oder temporärer Veränderungen gibt, lässt sich in den Übergangsbereichen von einer zur anderen Objektklasse im Referenz- und Klassifizierungsdatensatz ein Unschärfebereich definieren. Für diese Übergangsbereiche lassen sich Zugehörigkeitswerte mit Hilfe des FCM numerisch ausdrücken. Der Wertebereich liegt zwischen 0 und 1. Je höher der erreichte Wert ist, umso stärker korrelieren Ergebnis und

Referenz. Es wird der Vorschlag gemacht, ein gewichtetes Mittel aller FCM als Maß für alle Übergangsbereiche zu definieren.¹²⁴

¹²⁴ Schiewe, J. und Gähler, M. (2006): Modelling uncertainty in high resolution remotely sensed scenes using a fuzzy logic approach, 1. International Conference on Object-Based image Analysis 2006, Salzburg, ohne Seitenzählung