

Landnutzungsklassifikation auf multisensorischen und multispektralen Bilddaten - Anforderungen und Lösungsansätze

Carsten Lucht, Rico Nestler, Karl-Heinz Franke

Zentrum für Bild- und Signalverarbeitung e.V.

Gustav-Kirchhoff-Str. 5, 98693 Ilmenau

E-Mail: carsten.lucht@zbs-ilmenau.de

rico.nestler@zbs-ilmenau.de

karl-heinz.franke@zbs-ilmenau.de

URL: <http://www.zbs-ilmenau.de>

Zusammenfassung. Die Landnutzungs- / Landbedeckungsklassifikation im Rahmen der Fernerkundung ist eine sehr anspruchsvolle Bildverarbeitungsaufgabe. Der hohe Schwierigkeitsgrad resultiert vor allem aus einer starken Innerklassen-Heterogenität der Merkmalverteilung, welche Klassifikatoren mit hohem Freiheitsgrad bei der Klassenbeschreibung bzw. bei der Ausformung von Trennflächen erfordert. Die Klassifikation bedient sich dabei hochdimensionaler Merkmalvektoren, welche auf der Basis von multi- bzw. hyperspektralen, multisensorischen und multitemporalen Bilddaten erstellt werden. Die vektorielle Bildanalyse bildet damit methodisch eine große Schnittmenge mit der Farbbildverarbeitung. In Abwägung der Eigenschaften der betrachteten Klassifikatoren besitzen der Mischverteilungsklassifikator, der kNN-Klassifikator, der SVM-Klassifikator sowie der Random-Forest-Klassifikator hohes Potential, um die Anforderungen der Aufgabenstellung zu erfüllen. Im Verbundprojekt ENVILAND2¹ sind vor der Entwicklung eines Klassifikationsmoduls diese Annahmen zu prüfen. Erste Untersuchungsergebnisse bestätigen die Vorüberlegungen und geben ein positives Bild hinsichtlich der Erfüllbarkeit der bestehenden Anforderungen.

1 Einleitung

Die Landnutzungs- / Landbedeckungsklassifikation als wesentlicher Aufgabenkomplex in der Fernerkundung (Remote sensing) stützt sich bei der Untersuchung von Oberflächenarealen auf mehrkanalige Bilddaten, welche mittels leistungsfähiger Kamertechnik und Speziälsensorik in Befliegungsmissionen (Satellit, Flugzeug) erfasst werden. Zu den Bilddaten zählen seit jeher Multispektralaufnahmen aus dem VIS- und IR-Bereich (z. B. NASA Landsat-5 mit 7 Kanälen), aber zunehmend

1 gefördert mit Mitteln des Bundesministeriums für Wirtschaft und Technologie (BMWi) durch das Deutsche Zentrum für Luft- und Raumfahrt (DLR) unter der Fördernummer 50 EE 0845; weitere Projektpartner: Jena-Optronik GmbH, FSU Jena und ZFL Bonn

auch SAR(Synthetic Aperture Radar)-Daten (z. B. DLR TerraSAR-X) verschiedener Mikrowellenbänder und Polarisationen (siehe Abb. 1).

Der Kombination dieser multispektralen und multisensorischen Bilddaten zum Zwecke der automatischen Ableitung von anwendungsorientierter Landbedeckungsinformation widmet sich das aktuelle Verbundprojekt ENVILAND2, bei dem das ZBS e.V. insbesondere methodische F/E-Aufgaben innerhalb der gesamten Bildverarbeitungskette bearbeitet. Neben der Filterung, der Merkmalsextraktion, der Co-Registrierung von Bilddaten und Merkmalkarten sowie der Segmentierung bildet die Klassifikation den Schwerpunkt des Projektes. Das konkrete Ziel dieses Teilvorhabens besteht in der Entwicklung eines evaluierten Softwaremoduls für die Landnutzungsklassifikation mit unterschiedlichen Zielvorgaben.

In diesem Beitrag werden Anforderungen und Lösungsansätze für die Klassifikation von multisensorischen und multispektralen Bilddaten vorgestellt und diskutiert.




Abb. 1 Beispielszene „Nordhausen“, multispektrale und multisensorische Datenkanäle, links: Gesamtszene (RGB-Composite, Landsat-5-C3/Rot-C2/Grün-C1/Blau-Juli), rechts oben: typischer optischer Datenkanal (Landsat-5-C4/NIR-April), rechts unten: typischer SAR-Datenkanal (TerraSAR-X-Band-HH-Pol.-April)

2 Klassifikationsaufgaben und resultierende Anforderungen

Die Landnutzungs- / Landbedeckungsklassifikation muss im Kontext zahlreicher, teilweise recht unterschiedlicher Aufgabenstellungen durchgeführt werden. Hierzu zählen beispielsweise die Überwachung des Feldfruchtanbaus auf Agrarflächen, die Bestimmung des Versiegelungsgrades in urbanen Gebieten, die Ermittlung des Zuwachses von Siedlungsflächen oder die Abschätzung von Holzvolumen und Waldschäden in der Forstwirtschaft. Trotz des breitgefächerten Aufgabenspektrums lassen sich die Anforderungen für die Klassifikation in wesentlichen Punkten wie folgt verallgemeinern:

- **Überwachte Klassifikation**

Die Klassen sind a priori bekannt. Die Belehrung erfolgt mittels Ground-Truth-Karten, welche durch Feldarbeit (Datenerfassung vor Ort), Kartierungen bei

Ämtern oder Bildinterpretationen von Experten gewonnen werden. In zunehmenden Maße werden aber auch unüberwachte Klassifikationen für die automatische Erstellung von Lernmusterproben (Ausweisung von Trainingsgebieten) genutzt.

- **Ein- bis zweistellige Klassenanzahl**

In den typischen Anwendungen sind mindestens 8 Klassen zu unterscheiden, wobei gebräuchliche Nomenklaturen (z. B. Corine Landnutzung, LCCS) fünf Hauptklassen (Siedlungsgebiete, Wald, Landwirtschaft, Feuchtgebiete, Wasser) und weitere Unterteilungen auf verschiedenen Diversifikationsstufen festlegen (siehe Abb. 2).

- **Hochdimensionale Merkmalvektoren / Merkmalräume möglich**

Bei Nutzung von multispektralen und multisensorischen Daten ergeben sich pro Segment meist schon aus der mehrkanaligen Pixelstatistik hochdimensionale Merkmalvektoren, welche durch Ergänzung von Texturmaßen, morphometrischen Merkmalen (Segmentgröße, Konturmerkmale) sowie Merkmalen aus der lateralen Segmentnachbarschaft noch erheblich anwachsen können. Da sich viele Landbedeckungsklassen wesentlich in ihrer Phänologie (Entwicklungserscheinung im Jahresverlauf) unterscheiden, werden die Merkmalsätze bevorzugt aus multitemporalen Daten generiert, was mit einer weiteren Steigerung der Merkmalsdimension verbunden ist. Durch merkmalreduzierende Abbildung und Selektion sowie durch Gliederung in parallele und mehrstufige Klassifikationsprozesse kann die Dimension der Merkmalräume zumindest teilweise beschränkt werden.




Abb. 2 Beispielszene „Nordhausen“, links: Ground-Truth-Karte (Soll-Bild) für acht Klassen, rechts: Verteilung im dreidimensionalen Merkmalraum

- **Komplexe Merkmalverteilungen und starke Variation in einzelnen Klassen**

Landbedeckungsklassen, insbesondere Hauptklassen, weisen ein hohes Maß an Heterogenität (z. B. unterschiedliche Laubbaumarten) auf, welche eine große Varianz der Remission bewirkt. Hinzu kommen Streuungen bei der Datenerfassung, welche trotz bisweilen umfangreicher Datenkorrekturen (Atmosphärenkorrektur, Korrektur von topographischen Effekten) nur ungenügend begrenzt werden können. Exemplarisch seien hier tageszeitabhängige Beleuch-

tungsunterschiede (Veränderungen im reflektierten Spektrum, Streu- und Glanzeffekte, Schattenlagen) und meteorologische Einflüsse (z. B. Schneelagen, Wellenbewegung auf Wasser, Oberflächenfeuchtigkeit, atmosphärische Störungen) genannt. Bei niedrigen Ortsauflösungen stellen auch sogenannte „Mischpixel“, welche durch Überdeckung von Arealen unterschiedlicher Klassen entstehen, einen wesentlichen Störfaktor dar. In der Regel bilden die Landbedeckungsklassen komplexe Merkmalverteilungen, welche sich mit „einfachen“ Verteilungsfunktionen (z. B. multivariate Gaußverteilung) nur unzureichend beschreiben lassen. Einige Klassen weisen eine erhebliche gegenseitige Durchdringung auf (siehe Abb. 2).

- **Hohes Maß an Generalisierbarkeit**

Trotz komplexer, eng angrenzender Merkmalverteilungen der Klassen darf keine Überanpassung (Overfitting) an die Lernstichprobe erfolgen.

- **Geringe Lernmusterpräsenz bei einigen Klassen möglich**

In Bezug auf die Klassenpräsenz besteht eine erhebliche Heterogenität in der Bildszene. Zu einigen Klassen existieren oft nur wenige Lernmuster.

Angesichts der Komplexität der Aufgabenstellung ist die bei den meisten Anwendungen geforderte Klassifikationsgüte als hoch einzustufen. Für die allgemeine Landnutzungs-klassifikation mit relativ geringen Klassenanzahlen werden Werte von >85% richtige Klassenentscheidungen (Overall-Accuracy) angestrebt.

Die zu erzielende Rechenperformance ist hoch in Anbetracht der großen Datenmenge, welche bei Klassifikationsaufgaben in der Fernerkundung prozessiert werden muss. Zeitliche Zwänge (z. B. durch einen Arbeitstakt im Verarbeitungsprozess) bestehen aber nicht, so dass die Performance bei der Klassifikatorauswahl eher ein sekundäres Kriterium darstellt.

3 Ausgewählte Klassifikatoren und Lösungsansätze

Aus der anspruchsvollen Aufgabenstellung und schwierigen Randbedingungen resultieren hohe Anforderungen an den einzusetzenden Klassifikator sowie an die Strukturierung des Klassifikationsprozesses.

In der Literatur sind Anwendungen für eine breite Palette von Klassifikationsverfahren zu finden [Nie2003] [TSO2009] [LU 2007] [Rie2006]. Zu den am meisten bei der Fernerkundung eingesetzten Verfahren gehören Bayes- und Maximum-Likelihood-Klassifikatoren (ML) als statistische Klassifikatoren sowie der k-Nearest-Neighbor-Klassifikator (kNN) und der Hyperquader-Klassifikator (PPD, Parallelepipede) als Vertreter der trennflächenbasierten bzw. verteilungsfreien Klassifikatoren. Die Hyperquaderklassifikatoren führen direkt oder in Modifikationen bei der Abbildung auf Baumstrukturen, die als Decision-Trees (DT) bekannt sind. Mehre parallele Entscheidungsbäumen in Verbindung mit verschiedenen Ensemble-Learning-Strategien (Boosting, Bagging) bilden Decision-Tree-Gruppen (z. B. Random-Forest [Bre2001]), welche in jüngster Zeit immer wieder thematisiert werden [Was2007]. Daneben spielen für das diskutierte Applikationsfeld verstärkt wieder Support Vector Machines (SVM) eine Rolle, deren Grundlagen bereits in den 1970er Jahren entwickelt wurden. Weitere Anwendung finden Klassifikationsstrukturen, die den Künstlichen Neuronalen Netzen zuzuordnen sind, insbesondere Multilayer-Per-

ceptron (MLP), auf Adaptive-Resonance-Theory (ART) basierte Netze sowie mit Einschränkungen Selbstorganisierende Merkmalkarten (SOM) [TSO2009]. Neben Maximum-Likelihood-Prinzipien und verschiedenen Voting-Strategien werden häufig Fuzzy-Regeln in verschiedener Ausprägung für die Klassenzuordnung genutzt.

In Auswertung der bestehenden Anforderungen (Abschnitt 2) scheinen sowohl statistische Klassifikatoren als auch verteilungsfreie (trennflächenbasierte) Klassifikatoren für die Landnutzungsklassifikation geeignet. Die zu erwartende, komplexe Merkmalverteilung (siehe Abb. 2) favorisiert natürlich jene Klassifikatoren, welche einen hohen Freiheitsgrad bei der Beschreibung der Klassenverteilung bzw. bei der Ausformung von Trennflächen besitzen. Eine Beschränkung von Bayesschen Klassifikatoren auf eine multivariate Gaußverteilung der Klassenmerkmale wird den Anforderungen hier nicht gerecht. Wesentlich bessere Beschreibungen lassen sich mit partitionierender Clusterung und der Bildung von Mischverteilungen erreichen [Fra2004] [Mac1996]. Bei einer Mixture-of-Gaussians werden beispielsweise komplexe Verteilungen mit einer Linearkombination mehrerer multivariater Gaußverteilungen approximiert. Abb. 3 veranschaulicht den Gewinn bei der Klassenbeschreibung eindrucksvoll. Die Einbeziehung von Klassenpräferenzen nach dem Bayes-Prinzip (z. B. als a priori Wahrscheinlichkeiten der Klassen) sowie die hohe Kompaktheit der Beschreibung zeichnen die statistischen Klassifikatoren weiterhin aus.




Abb. 3 Klassenbeschreibungen für Beispielszene „Nordhausen“, links: mit einer multivariaten Gaußverteilung, rechts: mit Mischverteilung / partitionierender Clusterung (als Projektion in eine Merkmalebene visualisiert)

Durch die Unabhängigkeit von einem statistikbasierten, parametrischen Modell zur Beschreibung von Klassenbereichen lassen verteilungsfreie Klassifikatoren oft eine bessere Klassentrennung zu. Praktisch wird diese aber auch nur unter bestimmten Voraussetzungen erreicht. Der kNN-Klassifikator bedarf bei hochdimensionalen Merkmalräumen einer großen Lernmusterprobe, um eine ausreichende Sample-dichte auch in „dünn besiedelten“ Bereichen zu gewährleisten. Ähnliches gilt für Neuronale Netze, da das Verhalten in nicht belegten Bereichen unbestimmt ist. Zudem ist das Training, insbesondere bei großen Netzen (hohe Merkmaldimension, große Klassenanzahl, mehrere Hidden-Schichten), aufwendig und es bestehen keine konsistenten Regeln für ein hinsichtlich der Aufgabenstellung effizientes Netzwerk-Design. Neuronale Netze wie auch Decision-Trees neigen zu starker Überanpassung (Overfitting) an die Lernmusterprobe, dem jedoch durch geeignete

Maßnahmen (z. B. Klassifikator-Ensembles oder Pruning bei Decision-Trees) begegnet werden kann. Gegenüber Overfitting robust zeigen sich SVM-Klassifikatoren. Durch die Bildung von nichtlinearen Trennflächen² auf der Basis hinreichend weniger, aber gut positionierter Samples (Support Vektoren) sind hohe Klassifikationsgüten bei komplexer Merkmalverteilung selbst bei kleinem Lernmusterprobenumfang möglich [Nie2003] [TSO2009]. Ähnlich den Neuronalen Netzen hat die nutzerdefinierte Parametrierung (z. B. Auswahl der Kernfunktion) großen Einfluss auf das Klassifikationsergebnis. Des Weiteren sind die Performanceanforderungen bei der Belehrung nicht unerheblich.

Für das diskutierte Applikationsfeld werden Support Vector Machines, Decision-Tree-Ensembles (Random-Forest) und Mischverteilungsklassifikatoren als Klassifikationsverfahren favorisiert und sind Gegenstand nachfolgender Untersuchungen. Als Referenz werden ebenfalls der Maximum-Likelihood-Klassifikator (auf Basis einer multivariaten Gaußverteilung) und der kNN-Klassifikator betrachtet.

Neben der Auswahl des Klassifikationsverfahrens ist die Basis der Merkmalbestimmung festzulegen. Mit der Verfügbarkeit immer höher aufgelöster Bilddaten überwiegen die Vorteile der segmentbasierten (per-field) Klassifikation (Filterwirkung und robuste Statistik, zusätzliche Segmentformmerkmale) gegenüber der klassischen pixelbasierten (per-pixel) Klassifikation [LU 2007]. Aus diesem Grund und in Auswertung eigener Untersuchungen wird für die vorliegende Aufgabenstellung ein segmentbasierter Lösungsansatz verfolgt.

Die Komplexität der Aufgabenstellung, die hohe Merkmaldimension, die Datenheterogenität (insbesondere bei unterschiedlicher Sensoren), die erst spätere Verfügbarkeit von Merkmalen (z. B. lateraler Kontext klassifizierter Segmente) sowie Einschränkungen bzw. Überproportionen bei der Abbildung von Information (z. B. Straßennetzwerke, globale Merkmale) auf einen Merkmalvektor pro Segment führen zur Strukturierung der Klassifikation in einen mehrstufigen Prozess. Dabei sind verschiedene Kombinationen sinnvoll und mit Beispielen aus der Literatur belegt [TSO2009]. Sowohl die parallele Anordnung von gleichartigen oder unterschiedlichen Klassifikatoren mit anschließender Ergebnisfusion als auch die sequentielle Nutzung (z. B. segmentweise Vorklassifikation, nachfolgende Kontextklassifikation) sind gebräuchlich [LU 2007]. In [Was2007] wurde beispielsweise ein Konzept vorgestellt, welches multispektrale optische Bilddaten und multitemporale SAR-Bilddaten zunächst getrennt mittels SVM klassifiziert und anschließend diese Klassifikationsergebnisse durch eine weitere SVM-Klassifikation oder eine Random-Forest-Klassifikation zu einem Gesamtergebnis fusioniert. Als Lösung für die hier diskutierte Aufgabenstellung wird ein ähnlicher Ansatz verfolgt, wobei neben einem erweiterten Merkmalumfang (z. B. morphometrische Merkmale) auch die Kontextinformation der Segmente genutzt werden soll. Verschiedene Varianten der Strukturierung sind in nachfolgenden Untersuchungen zu testen.

² Hyperebenen in einem höherdimensionalen Raum, in welchen die Merkmalvektoren über eine nichtlineare Funktion (kernel functions: polynomial, radial basis function, sigmoid u. a.) transformiert werden

4 Implementierung und Erprobung

Die Entwicklung des Klassifikationsmoduls erfolgt in mehreren Stufen, wobei als erster Schritt und gleichzeitig Stand der aktuellen Projektbearbeitung eine Implementierung und Evaluierung von präferierten Klassifikatoren im VIP-Toolkit des ZBS e.V. erfolgt [VIP].

Das VIP-Toolkit ist ein leistungsfähiges Softwarepaket zum Rapid Prototyping von Bildverarbeitungslösungen. Die Software stellt eine umfangreiche Bibliothek von Algorithmen zur Bildverarbeitung (u. a. für mehrkanalige / Farb- Bildverarbeitung, Merkmalgewinnung und Klassifikation) bereit, die stets entsprechend neuer Anforderungen erweiterbar ist. Die Algorithmen können in einem grafischen Editor ausgewählt, parametriert, als Operatoren in sogenannten Pipelines miteinander kombiniert und auf verschiedene Daten angewendet werden (siehe Abb. 7). Das VIP-Toolkit bildet damit eine hervorragende Plattform für die Evaluierung der Klassifikatoren (Belehrung, Reklassifikation, Verifizierung), Merkmalauswahl und Strukturierung der Klassifikation.




Abb. 4 Schema für die Verifikation der segmentbasierten Klassifikation mit einem Merkmalsatz basierend auf multispektralen / multitemporalen Bilddaten

Von den in Abschnitt 3 ausgewählten Verfahren sind derzeit bis auf den Random-Forest alle Klassifikatoren als VIP-Toolkit-Operatoren verfügbar. Für die Validierung der Klassifikatoren wurden zu den einzelnen Phasen der Klassifikation (Belehrung, Kannphase) Operator-Pipelines erstellt. Eine schematische Darstellung des Verifikationsvorgangs zeigt Abb. 4. Dabei werden ausgehend von co-registrierten Bildkanälen nach kanalspezifischer Vorprozessierung (Speckle-Filterung u. a.) für jeden Bildkanal die Merkmale eines mit der Ground-Truth-Karte maskierten Segments bestimmt und zu einem Vektor zusammengefasst. Der belehrte Klassifikator trifft anhand dieses Merkmalvektors die Klassenentscheidung für das Segment. In dem nachgeschalteten Verifikationsmodul werden die jeweiligen Klassenentscheidungen aufgesammelt, mit den zugehörigen Ground-Truth-Labels verglichen, eine Fehlerstatistik (Konfusionsmatrix) erstellt und Gütekennwerte berechnet (siehe Abb. 7).

Zur exemplarischen Erprobung soll in diesem Beitrag eine Szene aus dem Raum Nordhausen / Goldene Aue (Nordthüringen) dienen (siehe Abb. 1). Es werden jeweils drei optische Kanäle (Landsat-5 C2/Grün, C4/NIR, C7/MIR) zu zwei verschiedenen Jahreszeiten (April, Juli) verwendet. Auf der in Abb. 2 dargestellten Ground-Truth-Karte (8 Klassen) werden durch zufällige Zerlegung von der Lernmusterprobe

unabhängige Segmente (hier 300 Segmente) erzeugt und die Mittelwerte der kanalweisen Pixelstatistik als Segmentmerkmale berechnet. Die Klassifikation anhand des Merkmalvektors und die Auswertung erfolgen für alle Klassifikatoren parallel. In Abb. 5 sind die Konfusionsmatrix sowie die Overall-Accuracy und der Kappa-Koeffizient als wesentliche Gütekennwerte für die verwendeten Klassifikatoren zusammengestellt. Abb. 6 zeigt exemplarisch das Klassifikationsergebnis für den kNN-Klassifikator.

	ML-Klassif.	Mischvert.- K.	kNN-Klassif.	SVM-Klassif.
Konfusionsmatrix (grauwertskaliert) Fehlklassifikationen außerhalb der Hauptdiagonale)				
Overall Accuracy ³ OA ∈ [0,1]	0.867	0.884	0.900	0.923
KHAT Accuracy ⁴ (Kappa-Koeff.) KHAT ∈ [-1,1]	0.841	0.863	0.881	0.908

Abb. 5 Klassifikationsergebnisse für die Beispielszene „Nordhausen“, Konfusionsmatrix und wesentliche abgeleitete Gütekennwerte [TSO2009]

Bei diesem Test wurde für den SVM-Klassifikator das beste Ergebnis erzielt, gefolgt von dem kNN-Klassifikator und dem Mischverteilungsklassifikator. Der ML-Klassifikator mit multivariater Gaußverteilung fällt in diesem Test kaum von der Güte der anderen Klassifikatoren ab, was der kompakten Merkmalverteilung in diesem Beispiel (siehe Abb. 2) zuzuschreiben ist. Bei Erhöhung der Verteilungskomplexität (zusätzliche Varianzmerkmale) in einem weiteren Test zeigten sich bereits deutliche Unterschiede, da der ML-Klassifikator im Gegensatz zu allen anderen Klassifikatoren keine Ergebnisverbesserung erzielen konnte. Die erhöhten Gütekennwerte (z. B. für kNN: OA=0.95 / KHAT=0.941) lassen sich vor allem auf die bessere Separierbarkeit der urbanen Klasse (Siedlungsgebiete) zurückführen, was sich in einer Reduzierung der diesbezüglichen Fehlklassifikationen (erste Zeile und erste Spalte der Konfusionsmatrix) ausdrückt.

Das Ergebnis der Erprobung deckt sich weitestgehend mit den Erwartungen. Es ist hier jedoch anzumerken, dass das genutzte Beispiel nur exemplarisch für die Aufgabenstellung ist. Zudem besteht hinsichtlich der Parametrierung, der Merkmal-

³ Klassifikationsgüte unter Berücksichtigung aller korrekten Klassenzuweisungen (Verhältnis aus der Summe aller richtig klassifizierten Samples (Hauptdiagonale der Konfusionsmatrix) zur Gesamtanzahl der klassifizierten Samples)

⁴ Klassifikationsgüte unter zusätzlicher Berücksichtigung der Randhäufigkeiten (gesamte Konfusionsmatrix) – Maß für die Stärke des deterministischen Zusammenhangs zwischen Klassifikationsergebnis und Referenzdaten

auswahl, der Belehrung sowie der algorithmischen Optimierung noch erhebliches Verbesserungspotential, was vor allem dem frühen Stand der Projektbearbeitung geschuldet ist. Eine detailliertere Analyse der erzielten Ergebnisse ist deshalb nicht sinnvoll. Die Ergebnisse stimmen jedoch optimistisch hinsichtlich der Erfüllung der bestehenden Anforderungen.




Abb. 6 Klassifikationsergebnis des kNN-Klassifikators für die Beispielszene „Nordhausen“, links: Klassifikationsergebnis (Ist-Bild), rechts: Fehlklassifikationen in der Bildszene (Landsat-5-C4/NIR-April), für Ground-Truth-Karte (Soll-Bild) siehe Abb. 2




Abb. 7 Klassifikator-Verifikation mit VIP-Toolkit, Ausschnitt aus der Operator-Pipeline, eine Named-Value-Liste der Gütewerte und eine grauwertskalierte Konfusionsmatrix (hier exemplarisch für den kNN-Klassifikator)

5 Resümee und Ausblick

Die Landnutzungs- / Landbedeckungsklassifikation im Rahmen der Fernerkundung ist eine sehr anspruchsvolle Bildverarbeitungsaufgabe. Der hohe Schwierigkeitsgrad resultiert vor allem aus einer starken Innerklassen-Heterogenität der Merkmalverteilung, welche Klassifikatoren mit hohem Freiheitsgrad bei der Klassenbeschreibung bzw. bei der Ausformung von Trennflächen erfordert. Der favorisierte Lösungsansatz für die Klassifikation ist mehrstufig strukturiert, erfolgt segmentbasiert und bedient sich hochdimensionaler Merkmalvektoren, welche auf der Basis von multi- bzw. hyperspektralen, multisensorischen und multitemporalen Bilddaten erstellt werden. In Abwägung der Eigenschaften der betrachteten Klassifikatoren und unter Einbeziehung erster Erprobungen im VIP-Toolkit besitzen der Mischverteilungsklassifikator, der SVM-Klassifikator, der kNN-Klassifikator sowie der Random-Forest-Klassifikator (noch keine Tests) hohes Potential, um die Anforderungen der Aufgabenstellung zu erfüllen. In den nachfolgenden Untersuchungen im Verbundprojekt ENVILAND2 gilt es diese Annahmen weiter zu prüfen, um schließlich eine fundierte Klassifikatorstrukturierung und Realisierung als Softwaremodul vorzunehmen.

Literatur

- [VIP] VIP-Toolkit, Zentrum für Bild- und Signalverarbeitung (ZBS) e.V., http://www.zbs-ilmenau.de/pdf/Flyer_1_VIPSoftware.pdf
- [Bre2001] Breiman, L.: Random forests. Machine Learning, vol. 45(1), pp. 5-32
- [Fra2004] Franke, K.-H.: Bildverarbeitung I und II; Vorlesungsskripte, Schriftenreihe des Zentrums für Bild- und Signalverarbeitung, ISSN 1432-3346
- [Mac1996] Machleidt, T., Franke, K.-H.: Farbklassifikation mittels partitionierender Clusteralgorithmen und Vergleich mit neuronalen Ansätzen, 2. Nationaler Workshop Farbbildverarbeitung, Schriftenreihe des Zentrums für Bild- und Signalverarbeitung, 1/1996, ISSN 1432-3346, pp. 61 - 64
- [Lu 2007] Lu D.; Weng Q.: A survey of image classification methods and techniques for improving classification performance; International Journal of Remote Sensing, Vol. 28, No. 5, 10 March 2007, pp. 823–870
- [Nie2003] Niemann, H.: Klassifikation von Mustern; Lehrstuhl für Mustererkennung, Universität Erlangen-Nürnberg, 2. überarbeitete und erweiterte Auflage im Internet: www5.informatik.uni-erlangen.de/fileadmin/Persons/NiemannHeinrich/klassifikation-von-mustern/m00links.html
- [Rie2006] Riedel, T.; C. Thiel, C.; Schmullius, C.; Franke, K-H: Extraktion von Landbedeckungsinformationen - ein automatisierter Ansatz mittels multitemporalen C-Band Daten; 1st Int. Conf. in Object-based Image Analysis (OBIA 2006), Salzburg, 04.07-05.07.2006
- [Tso2009] Tso, B.; Mather, P. M.: Classification methods for remotely sensed data; 2. Edition, 2009, CRC Press, Taylor & Francis, ISBN-13: 978-1-4200-9072-7
- [Was2007] B. Waske, V. Heinzl, M. Braun, G. Menz: Classification of segmented SAR and multispectral satellite imagery using Support Vector Machines; 52. Internationales Wissenschaftliches Kolloquium, Proceedings Vol. 2, Ilmenau, 2007, ISBN 978-3-939473-17-6