
Hochschule München

LEITFADEN ZUM PRAKTISCHEN EINSATZ DER BILDDATENFUSION IN DER FERNERKUNDUNG

Rebecca Zangl, Sarah Hauser, Andreas Schmitt

Zusammenfassung: Hunderte Fernerkundungssatelliten liefern täglich wertvolle Aufnahmen unseres Planeten. Jedoch hat jeder Satellitensensor nicht nur die viel gepriesenen Stärken, sondern auch – meist weniger bekannte – Schwächen. Um aus der Fülle an Aufnahmen optimale Informationsprodukte zu generieren, empfiehlt es sich, die Daten verschiedener Sensoren synergetisch zu kombinieren. So lassen sich die Schwächen des einen mit den Stärken des anderen ausgleichen und beispielsweise auch Beobachtungslücken schließen. So mannigfaltig wie die Sensoren sind auch die Ansätze zur Fusion ihrer Aufnahmen auf verschiedenen Ebenen. Dieser Beitrag gibt einen Überblick zu den heutzutage gebräuchlichen Verfahren zur Bilddatenfusion und ordnet die einzelnen Ansätze bezüglich Verarbeitungsebene, Methodik sowie Anwendung in einem dreidimensionalen Diagramm an. Aus jeder Gruppe werden exemplarische Ansätze und ihre Anwendungen vorgestellt und kritisch beleuchtet. Das Beispiel einer Wassermaske aus Sentinel-1 und Sentinel-2 illustriert die unterschiedlichen Fusionsebenen. In Summe ergibt sich ein Leitfaden für den praktischen Einsatz von Bildfusionsmethoden in der Fernerkundung: Wenn bereits adäquate Methoden zum Informationsgewinn aus Einzelaufnahmen vorhanden sind, empfiehlt sich die Fusion auf Entscheidungsebene für die großflächige Anwendung, wobei explorative Studien unbedingt die Informationsfülle auf Pixelebene fusionierter Bilddaten nutzen sollten.

Schlüsselwörter: Fernerkundung, Bildfusion, Pixelebene, Merkmalsebene, Entscheidungsebene, hyperkomplexe Basen

GUIDELINES FOR THE PRACTICAL USE OF IMAGE DATA FUSION IN REMOTE SENSING

Abstract: Hundreds of remote sensing satellites provide valuable images of our planet every day. However, each satellite sensor has not only the much-vaunted strengths, but also – mostly less known – weaknesses. In order to generate optimal information products from the abundance of images, it is advisable to synergistically combine the data from different sensors. In this way, the weaknesses of one can be balanced with the strengths of the other and, e. g., observation gaps can be closed. As manifold as the sensors are, so are the approaches to fuse their recordings at different levels. This article provides an overview of the current techniques for image fusion and arranges the individual approaches in terms of processing level, methodology as well as application in a three-dimensional diagram. Exemplary approaches and their applications from each group are introduced and critically examined. The example of a water mask from Sentinel-1 and Sentinel-2 illustrates the different fusion levels. This results in a guideline for the practical use of image fusion methods in remote sensing: if adequate methods for the information extraction from single images are already available, we recommend decision level fusion for large-scale application, whereas exploratory studies should rather take advantage of the pixel level fusion which typically holds the whole information content of the input layers.

Keywords: Remote sensing, image fusion, pixel level, feature level, decision level, hypercomplex bases

Autoren

M. Eng. Rebecca Zangl
M. Sc. Sarah Hauser
Prof. Dr.-Ing. Andreas Schmitt
Hochschule München
Fakultät für Geoinformation

Karlstraße 6
D-80333 München
E: rzangl@hm.edu
sarah.hauser@hm.edu
andreas.schmitt@hm.edu

1 EINLEITUNG

Die Internationale Gesellschaft für Photogrammetrie und Fernerkundung (ISPRS) definiert Fernerkundung wie folgt: „Remote sensing is the science and technology of capturing, processing and analysing imagery, in conjunction with other physical data of the Earth and the planets, from sensors in space, in the air and on the ground“ (Chen et al. 2016). Diese sehr allgemeine Definition besagt lediglich, dass die Fernerkundung sich mit der Verarbeitung bildhafter Daten der Erdoberfläche beschäftigt. Bildhaft bezeichnet dabei in einem regelmäßigen Raster vollautomatisch erfasste Eigenschaften. Im Gegensatz zu Vektordaten haben die einzelnen Bildelemente (Pixel) per se keine Bedeutung, sondern nur eine Lage, Ausdehnung und einen Wert. Die erfasste Eigenschaft bezieht sich meist auf die von einem Objekt emittierte oder reflektierte elektromagnetische Strahlung, welche auch aus weiterer Entfernung noch mit Sensoren wahrgenommen werden kann. Bei den Sensoren und ihren Plattformen hat sich in den letzten Jahrzehnten eine unglaubliche Vielfalt entwickelt: Die Abdeckung kann von nur wenigen Quadratmetern bis zur halben Erde innerhalb weniger Sekunden variieren. Die räumliche Auflösung reicht von mehreren Kilometern bis in den Subzentimeterbereich. Das Spektrum deckt von 200 nm (Ultraviolett) bis zu knapp 1 m (P-Band-Radar) im Bereich der atmosphärischen Fenster alles ab. Die Bandbreiten variieren von über tausend (Thermalkanäle Landsat) bis zu wenigen Nanometern (Spektrometer). Die Wiederholrate – allein aus dem All – schwankt zwischen etwa einem Monat und täglichen Aufnahmen. Im Radarbereich sind hinsichtlich Polarimetrie zahlreiche Varianten zwischen single-pol

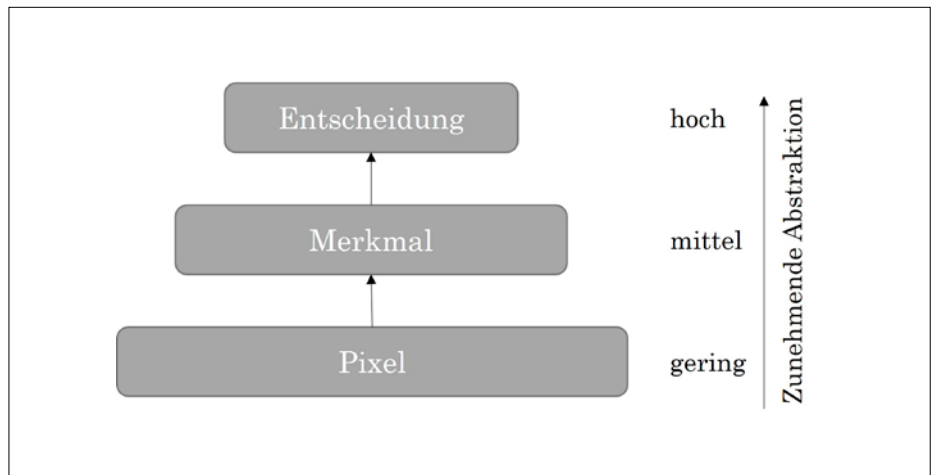


Abbildung 1: Verarbeitungsebenen, verändert nach Basaeed et al. (2012): Pixelebene entspricht dem Bildraum, Merkmalsebene bezieht sich bereits auf im Bild erkannte Bereiche oder aus den Bilddaten abgeleitete Indizes, während die Entscheidungsebene die Stufe darstellt, in der bereits Entscheidungen auf Basis der einzelnen Bilddaten getroffen worden sind

und quad-pol geboten. Auch bezüglich Interferometrie sind bereits diverse mono- und bistatische Systeme im operationellen Einsatz. Wozu braucht es bei solch einer Vielfalt an Sensoren und somit Aufnahmemöglichkeiten noch eine Datenfusion? Man möchte denken, dass man sich aus dieser Sammlung nur den richtigen herauspicken muss, der die (selbstverständlich) maximalen Anforderungen erfüllt. Leider wird bei diesem Wettrennen um den besten Sensor meist nur zwischen den Zeilen erwähnt, dass Spitzenleistung in einer Eigenschaft meist auf Kosten anderer Eigenschaften geht. Ein Beispiel: Der TerraSAR-X-Sensor kann 100 km breite Streifen abdecken, und er kann eine Bodenaufklärung von 50 cm erreichen. Für die 50 cm Bodenaufklärung reduziert sich jedoch die Abdeckung auf gerade einmal 5 x 5 km, wobei der Sensor davor und danach eine gewisse Zeit für weitere Aufnahmen blockiert ist. Flächende-

ckende Aufnahmen sind also in diesem Modus nicht möglich. Beim 100 km breiten Streifen reduziert sich die Bodenaufklärung auf 16 m (Eineder et al. 2013). Alle Spitzenleistungen in einer einzigen Aufnahme zu vereinen, geht folglich rein technisch nicht mit einem einzelnen Sensor, sondern nur durch die geschickte Kombination mehrerer Aufnahmen. Somit ergibt sich die Notwendigkeit einer Bilddatenfusion, um die Stärken über die Sensorgrenzen hinweg zu bündeln. Nach Van Genderen & Pohl (1994) ist Bildfusion die Kombination von zwei oder mehr verschiedenen Bildern zu einem neuen Bild unter Verwendung eines bestimmten Algorithmus. Weitere Definitionen werden in Veröffentlichungen von Schmitt & Zhu (2016) sowie Wald (1999) dargelegt.

Konkrete Ziele der Bilddatenfusion sind beispielsweise (1) die Verbesserung der Lagegenauigkeit durch Koregistrierung mit ei-

Benennung der Abstraktionsebenen				Entsprechende Veröffentlichung
	Pixel	Feature	Object	Basaeed et al. 2012
	Pixel	Feature/ Merkmal	Decision/ Entscheidung	Ghassemian 2016, Pohl & Van Genderen 1998, Abdikan et al. 2014, Gharbia et al. 2014, Komal & Dewan 2014, Li et al. 2011, Pandit & Bhiwani 2015, Schmitt & Zhu 2016, Zhao et al. 2003
	low	middle	high	Elmasry et al. 2020, Princess et al. 2014
	iconic	symbolic	knowledge	Ehlers et al. 2010
signal	iconic	symbolic	knowledge	Gupta & Mehra 2016, Jiang et al. 2011
roh	gering	mittel	hoch	Abstraktionsebene bzw. Verarbeitungslevel

Tabelle 1: Eingruppierung der Bilddatenfusionsansätze nach verschiedenen Veröffentlichungen. Die häufigste und auch in der Literatur übereinstimmend beschriebene Einteilung geschieht nach Pixel-, Merkmals- und Entscheidungsebene.

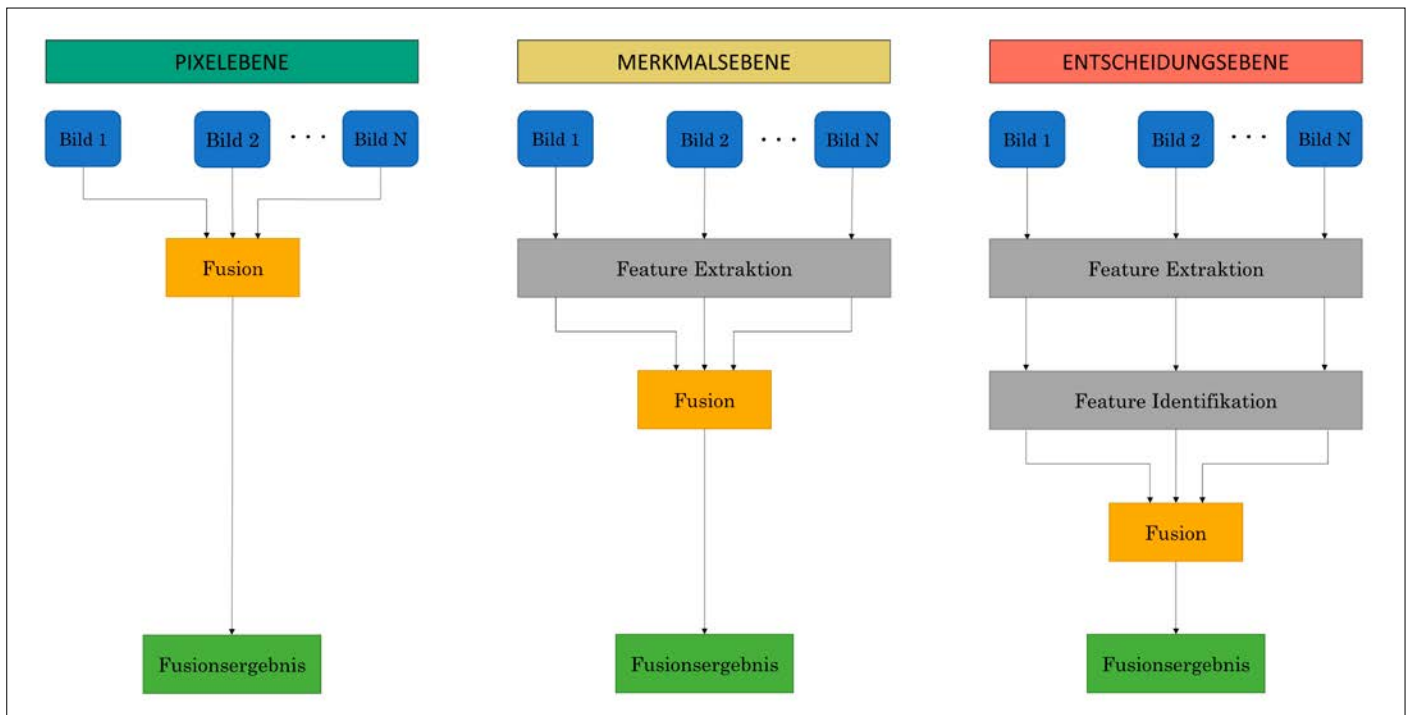


Abbildung 2: Schematische Darstellung der Pixel-, Merkmals- und Entscheidungsebene (verändert nach Pohl & Van Genderen 1998)

nem bereits geocodierten Bild, (2) das Füllen von Datenlücken, die durch Sensorfehler oder auch Abschattungen durch Wolken entstehen (Pohl & Van Genderen 1998), (3) die Erhöhung der spektralen Auflösung durch Hinzunahme von Farbinformation (Ranchin & Wald 2000), (4) die Erhöhung der räumlichen Auflösung durch Hinzunahme eines höchstauflösenden Grauwertbilds, (5) die Erhöhung der temporalen Auflösung durch die Kombination mehrerer Satellitensensoren in unterschiedlichen Orbits, (6) die Stabilisierung der radiometrischen Information durch Sensorkombination und ganz allgemein (7) die Steigerung der Informationstiefe.

Laut Choi (2006) soll eine ideale Bildfusionstechnik drei wesentliche Faktoren vereinen: ein hoher Durchsatz, den Erhalt der maximalen räumlichen Auflösung und die Reduzierung der Farbverzerrung. Dazu wurden verschiedene Maße entworfen und eingesetzt, die räumliche Muster, spektrale Charakteristiken und ganz allgemein den Informationsgehalt eines Bilds evaluieren.

Viele Fusionsmethoden haben sich im Arbeitsalltag bereits etabliert, andere sind noch Gegenstand der Forschung. In diesem Beitrag werden verschiedene Einteilungen der Methoden dargelegt, ausgewählte Methoden genauer beschrieben und diese abschließend diskutiert sowie gegeneinander abgewogen, um dem Leser einen Leitfaden

für den effektiven Einsatz von Bilddatenfusion in der Fernerkundung mitzugeben. Das Beispiel einer multisensoralen Wassermaske aus Sentinel-1 und Sentinel-2 veranschaulicht die einzelnen Fusions Ebenen.

2 EINTEILUNG DER FUSIONSMETHODEN

Die steigende Zahl der verschiedensten Fusionsmethoden kann schnell dazu führen, dass der Überblick verloren geht. Um trotzdem alle Methoden im Blick zu behalten, werden diese in Gruppen eingeteilt und nach der jeweiligen Vorgehensweise benannt. Dabei gehen verschiedene Autoren in ihren Reviews sehr unterschiedlich vor. Die Einteilung der Methoden nach dem Stand der Verarbeitung stellt eine sehr häufig verwendete Kategorisierung dar. Je nachdem, auf welchem Verarbeitungslevel die Fusion stattfindet, werden die Methoden in Pixelebene (Bildraster), Merkmals Ebene (besonderes Merkmal oder engl. Feature) oder Entscheidungsebene (bereits getroffene Entscheidung) eingeordnet. Die Entscheidungsebene bezieht sich dabei meist auf ein bestimmtes beobachtetes und klar abgegrenztes Objekt (siehe Abbildung 1).

Eine solche Einteilung erwähnen beispielsweise Ghassemian (2016), Pohl & Van Genderen (1998) (siehe Abbildung 2) sowie die Autoren Abdikan et al. (2014),

Gharbia et al. (2014), Komal & Dewan (2014), Li et al. (2011), Pandit & Bhiwani (2015), Schmitt & Zhu (2016) und Zhao et al. (2003). Zhang (2010) führt die gleiche Einteilung auf, kombiniert aber Merkmals Ebene und Entscheidungsebene zu High Level. Andere Bezeichnungen für die drei Verarbeitungslevel sind „low“, „middle“ und „high“ (Elmasry et al. 2020, Princess et al. 2014) oder „iconic“, „symbolic“ und „knowledge“ (Ehlers et al. 2010). Gupta & Mehra (2016) sowie Jiang et al. (2011) fügen vor der Ebene der Pixel ein Signal Level hinzu. Dieser beschreibt die Kombination von Signalen verschiedener Sensoren, um ein neues Signal zu generieren, das ein besseres Signal-Rausch-Verhältnis hat als die Ausgangssignale (Gupta & Mehra 2016, Jiang et al. 2011). Tabelle 1 gibt hierzu eine Übersicht.

Da es eine Vielzahl an Fusionsmethoden auf Pixel Level gibt, werden diese nun weiter in unterschiedliche Untergruppen aufgeteilt. Pohl & Van Genderen (1998) nennen dabei die beiden Klassen der farbbezogenen Methoden und statistischen/numerischen Methoden sowie kombinierte Ansätze. Eine andere Unterteilung, bei dem das Pixel Level die Klassen Component Substitution, Multi-Resolution Analysis und Model- bzw. Modulationsbasiert umfasst, ist weit verbreitet (Gamba & Chanussot 2008, Kahraman & Ertürk 2017). Zhang (2010)

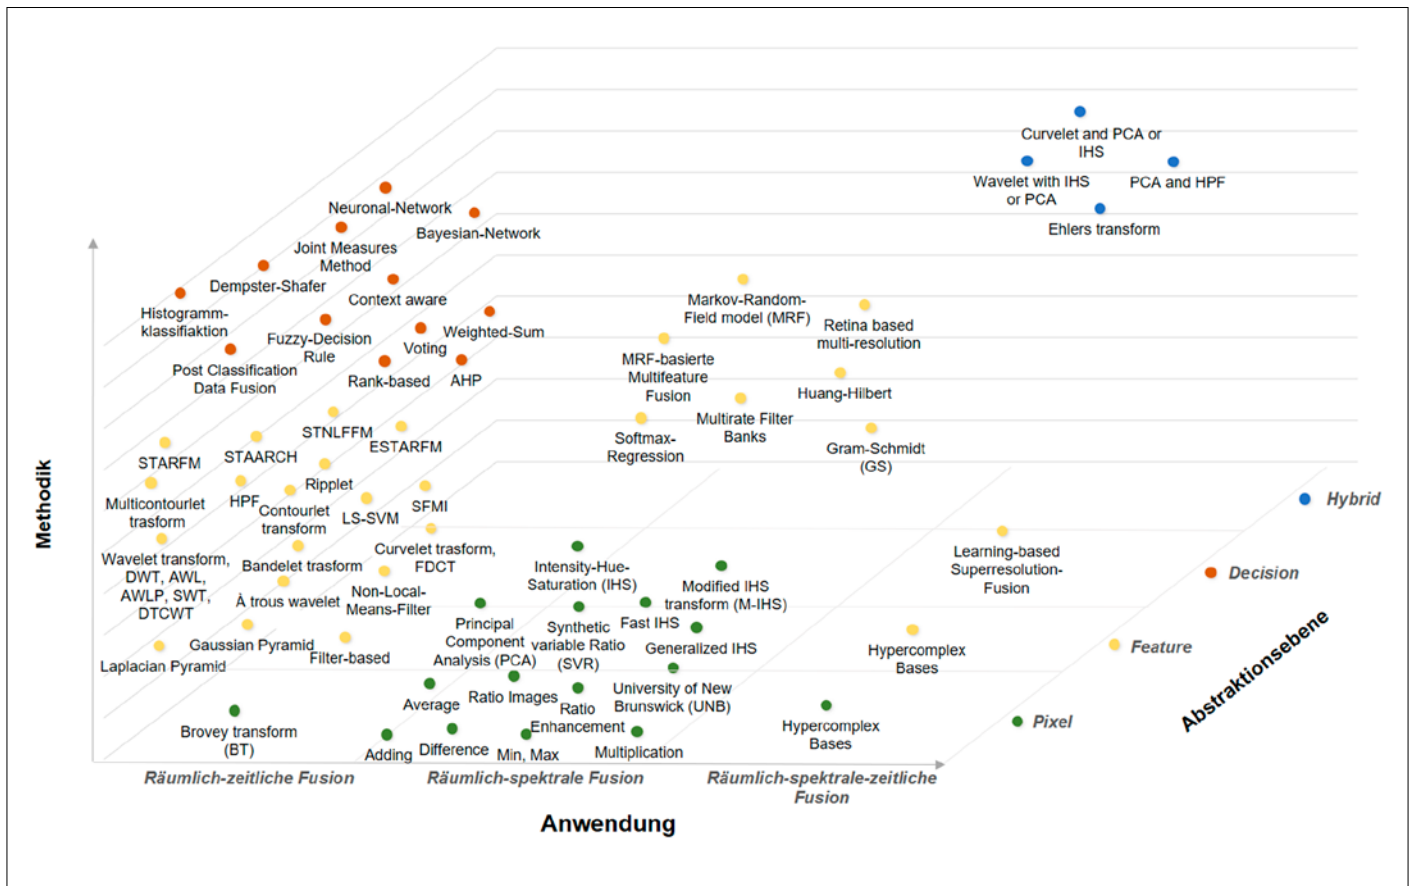


Abbildung 3: Aktualisierte Einteilung der Fusionsmethoden nach Abstraktionsebene (Pixel, Merkmal, Entscheidung und Hybrid), Anwendungen (räumlich-zeitliche Fusion, räumlich-spektrale Fusion und räumlich-spektrale-zeitliche Fusion) und der Methodik

und Ghassemian (2016) fügen noch Hybride Ansätze als vierte Gruppe hinzu. Mit Ausnahme der modellbasierten Klasse greifen auch Pandit & Bhiwani (2015) diese Einteilung so auf. Sie erwähnen die zusätzliche Klasse der „Relative spectral contribution methods“. Auch Loncan et al. (2015) nennen keine modellbasierte Klasse, sondern gliedern in „Bayesian“ und „Variational“.

Eine andere Eingruppierung der Fusionsmethoden umfasst den Bildraum und den Frequenzraum, wie von Li et al. (2011), Elmasry et al. (2020), Gupta & Mehra (2016) und Komal & Dewan (2014) vorgeschlagen. Frequenzraum bezeichnet dabei nicht nur klassisch die Fourier-Transformation, sondern umfasst ebenso die große Gruppe der Wavelet-Transformationen. Die Vorgehensweise ist immer gleich: Während im Bildraum direkt die einzelnen Pixelwerte unabhängig von ihrer Nachbarschaft zusammengefasst werden, kombiniert man im Frequenzraum (lokale) Schwingungen und transformiert das fusionierte Bild anschließend zurück in den Bildraum (Gupta & Mehra 2016). Ergänzend zu diesen Unter-

gruppen werden die Deep-Learning-Domäne von Schmitt et al. (2020), die statistische Domäne von Balachander & Dhanasekaran (2016) und die Optimierungsdomäne von Ha et al. (2012) genannt.

Ausgehend von Ghassemian (2016) und Gupta & Mehra (2016) wird in diesem Beitrag eine neue, dreidimensionale Einteilung der aktuell eingesetzten Fusionsmethoden entwickelt. Anders als bei den bisherigen Einteilungen werden nun auch die Anwendungen in den Kriterienkatalog mit aufgenommen, weil sich nicht jede Fusionsstrategie auch für jede Anwendung gleich gut eignet. Da es bisher eher darum ging, ein konkretes Produkt zu verbessern (z. B. Pansharpener einer Multispektralaufnahme) und nicht die maximale Informationstiefe herauszuholen, wurde dieser Punkt bisher wenig beleuchtet. Somit ergeben sich für die neue Einteilung drei Achsen: Abstraktionsebene, Methodik und Anwendung (siehe Abbildung 3). Die Abstraktionsebene unterteilt sich so in die folgenden vier Fusionsmethoden: Pixel, Merkmal, Entscheidung sowie Hybrid. Die „signal“-Ebene wird explizit weggelassen, weil alleine schon die

räumliche Registrierung zweier Bilder einer Interpolation und somit Aufbereitung der ursprünglichen Messungen bedarf. Für die nicht ganz so einfach zu definierende Grenze zwischen Pixel Level und Feature Level orientiert sich die neue Einteilung an der Definition von Hall (1992): Zum Pixel Level gehört alles, was nur ein einzelnes Pixel unabhängig von seiner Umgebung betrachtet. Sobald benachbarte Pixel oder auch Kanäle in Betracht gezogen werden, wird das Verfahren dem Feature Level zugeordnet, weil ja räumliche oder spektrale Features in die Fusion eingehen. Unter Anwendung stehen die angestrebten Fusionsanwendungen im Fokus: die räumlich-temporale Fusion, die räumlich-spektrale Fusion sowie die räumlich-spektrale-temporale Fusion. Die Ebene der Methodik indiziert den steigenden Grad der Komplexität, der Vorverarbeitungsstufe, der Flexibilitäts- und Automationsmöglichkeiten, das Datenvolumen und die Verarbeitungsgeschwindigkeit der jeweiligen Fusionsmethode.

Die pixelbasierte Fusion ist der einfachste und direkteste Ansatz für die Fusion mehrerer Bilder durch die Durchführung von

Pixel-zu-Pixel-Operationen. Diese Ansätze zeichnen sich durch eine geringe Komplexität in der Umsetzung sowie durch einen hohen Grad an Flexibilität und Automationsmöglichkeiten aus. Auch das Datenvolumen ist ein sehr wichtiger Aspekt in der Fusion von Fernerkundungsdatensätzen. Mit einer gut durchdachten Fusion können Rohbilder (z. B. HS und PAN) separat gespeichert und nur nach Bedarf fusioniert werden. Daher ist die Speicherung von „Rohdatensätzen“ und deren bedarfsgerechte Fusion eine wirksame Strategie, welche die Datenspeicherung und -umwandlung erleichtert. Die Fusion auf Merkmalsebene ist eine komplexere Ebene der Fusion, die im Gegensatz zu pixelbasierten Operationen heterogene Daten, die sich in Modalität und Quelle unterscheiden, effizient verarbeiten kann. Während sich Automation und Flexibilität von Fusionen auf Merkmalsebene als komplexer darstellen, zeichnen sich diese Fusionen durch eine geringe Verarbeitungsgeschwindigkeit aus. Die Fusion auf der Entscheidungsebene erfolgt auf einer Ebene, auf der die Bilder vollständig und unabhängig voneinander verarbeitet werden müssen bis ein aussagekräftiges Ergebnis, wie z. B. eine Klassifizierungs- oder eine Änderungskartierung, vorliegt. Da die Datenquellen auf der Entscheidungsebene unabhängig voneinander analysiert werden, haben die spektralen, räumlichen und radiometrischen Auflösungen der Bilder im Gegensatz zu den Fusionstechniken auf Pixelebene keinen großen und strengen Einfluss auf den Fusionsprozess.

Auswählte Verfahren aus der Literatur werden im Folgenden genauer beschrieben.

3 BEISPIELE FÜR FUSIONSALGORITHMEN

In diesem Kapitel werden für die einzelnen Kategorien repräsentative Verfahren samt ihren Anwendungen vorgestellt. Die jeweiligen Verfahren sind in Abbildung 3 dargestellt und im Anhang in Tabelle A1 samt Literaturangaben gelistet. Die Tabelle umfasst dabei noch weitere, hier nicht näher erläuterte Verfahren der einzelnen Gruppen.

3.1 PIXEL LEVEL

Die Fusion auf Pixelebene findet auf einer niedrigen Verarbeitungsstufe statt, wie in Abbildung 1 und Abbildung 3 zu sehen ist. Hierbei werden fast die Rohdaten zusammengeführt (Schmitt & Zhu 2016, Zhang

2010). Lediglich Sensor- und Atmosphärenkorrekturen geometrischer und radiometrischer Natur werden vorab angewendet, um reproduzierbare physikalische Parameter zu erhalten (Pohl & Van Genderen 1998) und eine adäquate Koregistrierung zu garantieren. In Abbildung 2 ist das Vorgehen bei der Pixel-Level-Fusion schematisch dargestellt: Es gibt in der Regel keine Aufbereitung zwischen Einzelbildern und Fusion wie bei der arithmetischen Kombination. Eine erste Ausnahme bilden bereits die hyperkomplexen Basen, die eine Transformation des Spektralraums erfordern, ebenso wie die Verfahren der Komponentensubstitution. Beide werden jedoch trotzdem zum Pixel Level gezählt, weil die Transformationen nur Hilfskonstrukte darstellen, die das Verständnis erleichtern, aber für die Interpretation nicht essenziell sind. Die Klassen werden nachfolgend kurz erläutert und anschließend wird jeweils eine Methode genauer beschrieben.

Arithmetic Combination

Bei der Klasse der arithmetischen Kombination werden einfache mathematische Operatoren verwendet, um Bilder miteinander zu kombinieren (Pohl & Van Genderen 1998). Diese sind beispielsweise Addition, Subtraktion, Durchschnitt, Verhältnis, aber auch die Brovey-Transformation, welche im Folgenden genauer erklärt wird. Die Brovey-Transformation nutzt die mathematischen Rechenoperatoren Addition, Multiplikation und Division, um so ein Farbbild mit einem hochaufgelösten Bild zu kombinieren (Pohl & Van Genderen 1998). Zunächst wird jedes der drei Bänder des RGB-Bilds mit dem hochaufgelösten panchromatischen Bild multipliziert, wodurch dem RGB-Bild eine räumlich höheraufgelöste Helligkeitskomponente hinzugefügt wird. Die Ergebniskanäle werden im nächsten Schritt durch die Summe aller multispektralen Bänder (entspricht der panchromatischen Helligkeit) geteilt, um diese zu normalisieren (Ha et al. 2012).

Hypercomplex Bases

Die Methoden der hyperkomplexen Basen verwendet zwar auch nur grundlegende arithmetische Operationen, jedoch in einem fest vorgegebenen Rahmen: Die Transformationen sind immer orthogonal und die entstehenden Elemente können sowohl linear als auch über eine entsprechende Normalisierung logarithmisch oder als Index auf

einen festen Wertebereich normiert ausgegeben werden. Der Ansatz entwickelt die Idee der Kennaugh-Elemente weiter, welche bereits für die Aufbereitung von SAR-Bildern (Schmitt et al. 2015) und zum SAR-Sharpening (Schmitt & Wendleder 2018) erfolgreich verwendet worden sind. Kern der hyperkomplexen Basen ist die Darstellung der Eingangskanäle über Gemeinsamkeiten und Unterschiede. Mathematisch ausgedrückt ergibt sich daraus folgende Matrix:

$$C = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}$$

Mit dem Vorfaktor $\sqrt{\frac{1}{2}}$ entsteht eine orthogonale Abbildung des Merkmalsraums, d. h. die transponierte Matrix ist gleich ihrer Inversen und aufgrund der Symmetrie somit ihre eigene Inverse, also in beide Richtungen einsetzbar. Diese Eigenschaft garantiert einerseits, dass beispielweise der Spektralraum nicht verzerrt wird, und andererseits, dass die Transformation ohne Informationsverluste umkehrbar ist. Die erste Zeile enthält lauter Einsen mit positivem Vorzeichen, die zweite Zeile eine Eins mit positivem und eine Eins mit negativem Vorzeichen. Bei Multiplikation mit einem Vektor wird also die Summe (erste Zeile) und die Differenz (zweite Zeile) der beiden Eingangskanäle berechnet, unabhängig davon, ob es sich um Radarintensitäten oder spektrale Reflektanzen handelt. Die obige Darstellung aus der Theorie der komplexen Zahlen kann ohne Weiteres mit Substitution der einzelnen Einträge auf beliebige Zweierpotenzen erweitert werden, z. B. zur Quaternionenbasis (Schmitt et al. 2020) (Formel 1).

$$Q = \begin{bmatrix} C & C \\ C & -C \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & -1 & 1 & -1 \\ 1 & 1 & -1 & -1 \\ 1 & -1 & -1 & 1 \end{bmatrix} \quad (\text{Formel 1})$$

Auch acht (Oktonionen) und sechzehn (Sedenionen) Dimensionen können auf diese Weise verarbeitet werden. Bei Anwendung auf Vierkanal-Luftbilder oder die 10-m-Bänder von Sentinel-2 werden die Spektralkanäle Blau, Grün, Rot und (nahes) Infrarot (NIR) auf hyperkomplexen Basen fusioniert zu sogenannten Kennaugh-Like-Elementen (siehe Abbildung 4). Traditionell werden die Kanalkombinationen Echtfarbenbild TCI (R:

Rot, G: Grün, B: Blau) und Farbinfrarot CIR (R: NIR, G: Rot, B: Grün) ausgegeben. Die Transformation via hyperkomplexe Basen trennt Helligkeitsinformation (Abbildung 4: Bild rechts oben) von spektraler Information (Abbildung 4: Bild rechts unten); mathematisch ausgedrückt ergibt sich Formel 2.

$$K_{\text{spektral}} = Q \cdot \begin{bmatrix} \text{Blau} \\ \text{Grün} \\ \text{Rot} \\ \text{NIR} \end{bmatrix} \quad (\text{Formel 2})$$

Auf dieser Basis entsprechen die optischen Aufnahmen – rein vom Wertebereich her – den in Kennaugh-Elementen abgelegten multipolarisierten Radaraufnahmen von Sentinel-1, z. B. aus dem Multi-SAR-Prozessor des Deutschen Zentrums für Luft- und Raumfahrt (Schmitt et al. 2015), und können somit problemlos mit diesen fusioniert werden (Schmitt et al. 2020) (Formel 3).

Die Fusion aus vier polarimetrischen und vier spektralen Kanälen ergibt konsequenterweise acht Kanäle auf hyperkomplexen Basen, da durch die Fusion aufgrund der Orthogonalität per Definition keine Information verloren geht.

Component Substitution

Die Klasse der Komponentensubstitution basiert darauf, eine Komponente eines Bilds gegen eine andere eines zweiten Bilds auszutauschen, um die Vorteile der Bilder zu kombinieren. Um dies zu erreichen, sind drei Schritte notwendig. Der erste Schritt besteht aus einer Vorwärtstransformation auf das multispektrale Bild (Zhang 2010). Durch diese Transformation wird die in allen Kanälen gleichermaßen vorhandene räumliche Struktur von der spektralen Information getrennt und ähnlich zu den hyperkomplexen Basen in verschiedene Komponenten aufgeteilt. Im nächsten Schritt wird die Komponente, welche die räumliche Struktur des multispektralen Bilds am besten wiedergibt, meist die Gesamthelligkeit, durch eine andere Komponente mit feinerer räumlicher Auflösung, z. B. ein hochaufgelöstes panchromatisches (PAN) Bild ersetzt. Das fusionierte Bild wird zuletzt mit der inversen Transformation zurücktransformiert (Ghamisi et al. 2019, Ghassemian 2016). Ein multispektrales Bild mit schlechterer räumlicher, aber besserer spektraler Auflösung, wird mit einem PAN-Bild, welches

$$K_{\text{fusioniert}} = \begin{bmatrix} K_{\text{spektral}} + K_{\text{polarimetrisch}} \\ K_{\text{spektral}} - K_{\text{polarimetrisch}} \end{bmatrix} \triangleq C \cdot \begin{bmatrix} \text{spektral} \\ \text{polarimetrisch} \end{bmatrix} \quad (\text{Formel 3})$$

eine höhere räumliche Auflösung aufweist, fusioniert, um die begehrten Eigenschaften beider Bilder zu kombinieren. Das Ergebnis ist ein multispektrales Bild mit der räumlichen Auflösung des PAN-Bilds. Dieses Verfahren wird häufig zum PAN-Sharpening eingesetzt (Ghassemian 2016).

Im Folgenden wird die IHS-Fusionsmethode als Standardverfahren der Fusionsmethoden (Pohl & Van Genderen 1998) näher erläutert. IHS steht für Intensity (Intensität), Hue (Farbton) und Saturation (Sättigung). Diese drei Komponenten bilden ein Farbsystem zur Darstellung von Dreikanalbildern (Gupta & Mehra 2016). Die räumliche Information steckt nun hauptsächlich in der I-Komponente (gleichbedeutend mit der Gesamtintensität der hyperkomplexen Basen oder dem panchromatischen Kanal), während die spektrale Information in den anderen beiden Komponenten enthalten ist (Balachander & Dhanasekaran 2016). Die Intensitätskomponente wird durch ein räumlich höher aufgelöstes panchromatisches Bild ersetzt. Um Farbverzerrungen zu vermeiden, wird das PAN-Bild an die I-Komponente histogrammangepasst oder die H- und S-Komponenten werden entsprechend gestreckt. Abschließend wird die inverse IHS-Transformation angewendet, um das fusionierte Bild im ursprünglichen RGB-Farbraum zu erhalten (Fonseca et al. 2011).

3.2 FEATURE LEVEL

Betrachtet man ein Pixel isoliert, kann es unvollständige Informationen über die gewünschten Merkmale liefern. Betrachtet man das Pixel jedoch in seinem Kontext, lassen sich vollständigere Informationen ableiten. Durch die Zusammenführung von Multiquellen- und Multitemporaldaten mit räumlichen Informationen wird die Klassifizierungsgenauigkeit verbessert. Deshalb befassen sich Fusionsmethoden auf Merkmalsebene mit Daten auf höheren Verarbeitungsstufen (Abbildung 1). In der Regel werden zuerst Methoden zur Merkmalsextraktion verwendet, erst danach erfolgt der Fusionsprozess. Da die extrahierten Merkmale bereits Informationsträger sind, bleibt nach der Fusion der Schritt zurück zu den Rohdaten oft aus.

Merkmale oder Features können dabei geometrische, strukturelle, statistische oder spektrale Eigenschaften sein (Hall 1992). Beispiele hierfür sind Kanten, Textur, Form, Winkel/Richtung, Nachbarschaft und Ausdehnung (Pandit & Bhiwani 2015, Pohl & Van Genderen 1998) oder auch spektrale Indizes wie der häufig verwendete Normalized Difference Vegetation Index (NDVI). Zur Extraktion geometrischer Merkmale werden Textur-Filter, Bildraumtransformationen oder auch Segmentierungsverfahren angewendet (Ghassemian 2016). Einen weiteren Ansatz stellt der Multiresolution Segmentation Algorithm (MRS) (Batz & Schäpe 2000) dar, ein patentierter Algorithmus des Softwarepakets eCognition Developer (Trimble Geospatial Imaging) zur Segmentierung von Bildszenen. Der MRS-Algorithmus ist ein Bottom-up-Verfahren zur Zusammenführung von Regionen. In einem iterativen Prozess auf verschiedenen Ebenen fasst der Algorithmus einzelne Pixel zu immer größeren Segmenten zusammen. Dabei werden folgende Entscheidungsparameter berücksichtigt: (1) Maßstab, (2) Form, (3) Kompaktheit. Berger et al. (2018) nutzen zunächst eine Quadtree-basierte Segmentierung, um die resultierenden Objektprimitive mittels des MRS zu fusionieren. Dabei wurden ähnliche Segmente mithilfe der auf mehreren Objektdifferenzbedingungen basierenden Fusion weiter zusammengeführt. Nach der Segmentierung wurden robuste Merkmale wie der normalisierte Differenzvegetationsindex (NDVI) (Tucker 1979), Bildhelligkeit und Höheninformationen ausgewählt, um verschiedene Landbedeckungstypen auf der Basis von normalisierten Wertebereichen zu klassifizieren.

Ähnliche Features aus unterschiedlichen Quellen werden einander zugeordnet und über unterschiedliche Ansätze fusioniert (Ghassemian 2016, Pohl & Van Genderen 1998). Die Bilder werden also auf Grundlage der Eigenschaften der zugehörigen Features der Eingangsbilder kombiniert (Basaed et al. 2012). Dies ist in Abbildung 2 dargestellt. Im Folgenden werden wieder repräsentative Verfahren für die gebräuchlichen Klassen Multiresolution Analysis, Mo-

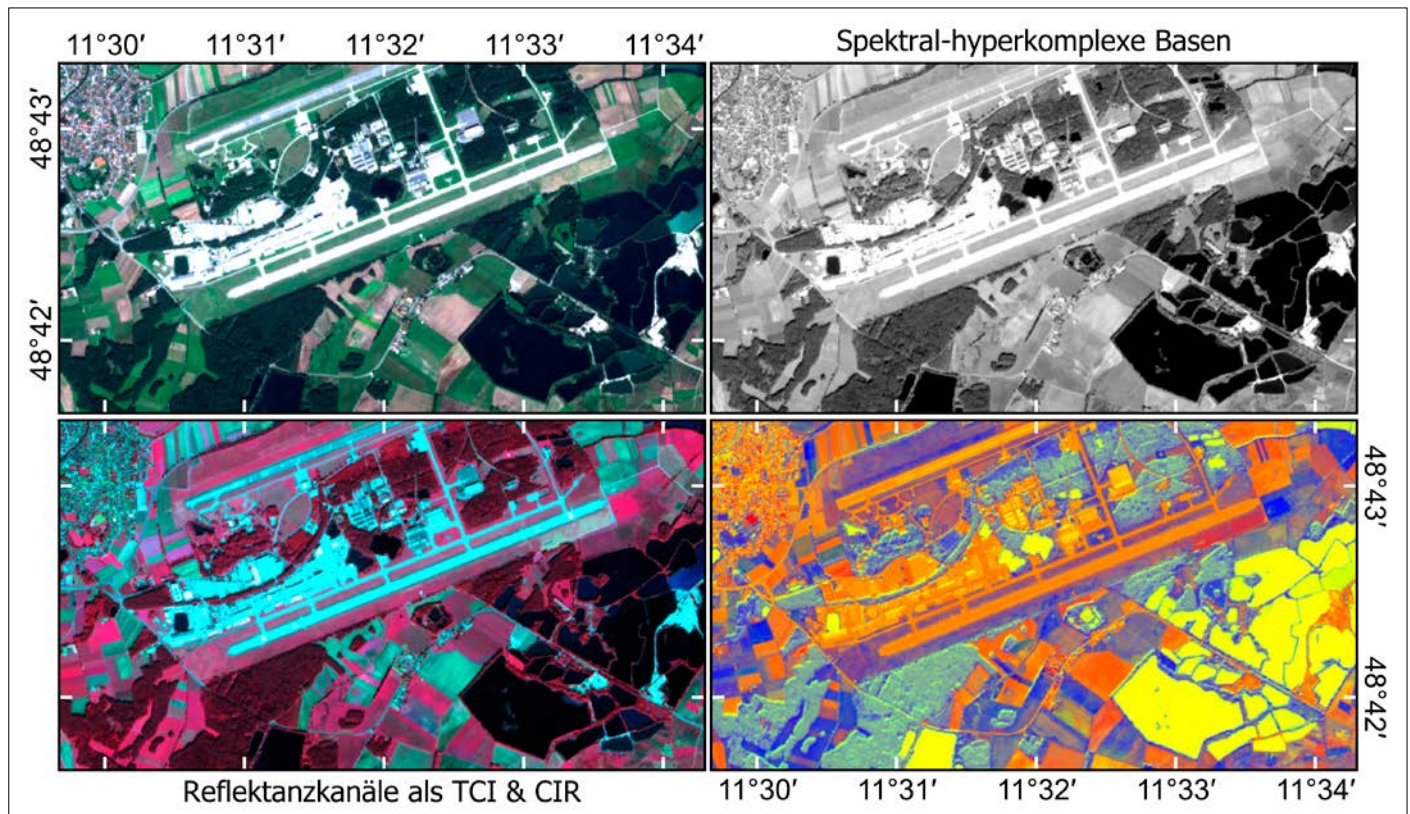


Abbildung 4: Links die traditionelle Darstellung eines Vierkanalbilds von Sentinel-2 (© ESA 2021) als Echtfarbenbild (TCI) oben und Farbinfrarotbild (CIR) unten. Rechts zu sehen ist die Darstellung auf spektral-hyperkomplexen Basen mit der Gesamtintensität oben und den drei normierten spektralen Informationskanälen unten. Der Ausschnitt zeigt den Flughafen Ingolstadt/Manching in Oberbayern.

del-based Approaches und Hypercomplex Bases vorgestellt.

Multiresolution Analysis

Die Fusion mittels Multiresolution Analysis (MRA) besteht wie die Komponentensubstitution aus drei Schritten. Zunächst werden die Bilder mithilfe von Multiskalen-Zerlegungsmethoden (Bildpyramiden, Frequenzraum-Transformationen etc.) in mehrere Skalenebenen zerlegt (Ghassemian 2016, Zhang 2010). Der nächste Schritt besteht aus der Fusion der Bilder. Es werden räumliche Details abgeleitet, welche in die multispektralen Bilder eingefügt werden (Zhang 2010). Im letzten Schritt findet die inverse Transformation statt (Ghassemian 2016, Zhang 2010).

Das Multirate-Verfahren auf Basis der Fourier-Transformation stellt eine Möglichkeit der multiskaligen und die Curvelet-Transformation zusätzlich der gerichteten Bildfusion dar. Beide werden im Folgenden genauer beschrieben.

Durch ein Multirate-Filterverfahren können multispektrale Bilder mit räumlichen Features verbessert werden. Ein räumlich hochaufgelöstes PAN-Bild sowie ein räumlich niedriger aufgelöstes multispektrales

Bild werden über die Fourier-Transformation als Prozess der Feature-Extraktion in den Frequenzraum überführt. Das niedrig aufgelöste Bild nimmt die unteren Frequenzen ein, während sich das panchromatische Bild im hochfrequenten Bereich befindet. Dieses Schema basiert also auf einem Multirate-Filter-Bank-Bildsynthesizer. Die Energie, welche die spektralen Features enthält, wird in den niedrigeren Frequenzteilbändern verteilt, während die räumlichen Features, also die Kanten, in den höheren Frequenzteilbändern verteilt werden. Die multispektralen Bilder werden räumlich verbessert, indem die aus dem hochaufgelösten Bild abgeleiteten räumlichen Features mit einem inversen Teilbandcodierungsverfahren hinzugefügt werden. Dies wird mithilfe von zwei Filtern erreicht, einem mit hoher und einem mit niedriger räumlicher Auflösung. Diese Filter können als radiale Frequenz-Bandpassfilter beschrieben werden, die die gewünschten Merkmale jedes Bilds, also räumliche oder spektrale Merkmale, bewahren (Ghassemian 2001b, Ghassemian 2016).

Curvelet-Transformationen existieren als erste Generation und als weiterentwickelte zweite Generation namens Fast Discrete

Curvelet Transformation (Rao et al. 2014). Curvelets wurden auf der Grundlage der Wavelet-Theorie entwickelt und sind eine Multiskalen-Methode nach Ridgelet mit Bandpassfilterung (Nencini et al. 2007, Wu et al. 2018). Der Grundgedanke der Curvelet Transformation ist die bestmögliche Darstellung von Kurven. Sie besteht aus vier Hauptschritten. Zunächst wird das Bild in Teilbänder zerlegt, dann wird jedes Teilband in gleichmäßige Quadrate einer geeigneten Skala aufgeteilt. Der nächste Schritt besteht darin, jedes Quadrat auf eine Einheitsgröße zu normieren (Choi et al. 2005). Abschließend wird die Ridgelet-Transformation angewendet, mit der gerade Kanten mit unterschiedlichen Steigungen und Ausrichtungen sowie durch die Einteilung des Bilds in quadratische Blöcke auch Kurven dargestellt werden können (Nencini et al. 2007). So wird jedes Quadrat analysiert (Choi et al. 2005). Curvelets sind richtungsabhängig und erfüllen die anisotrope Skalierungsbeziehung $\text{Breite} \approx \text{Länge}^2$ im räumlichen Bereich (Pandit & Bhiwani 2015). Die Curvelet-Koeffizienten, welche für jedes Bild abgeleitet werden, können nun zu neuen Koeffizienten kombiniert werden. Diese bieten

drei Möglichkeiten zur Beeinflussung: Skala, Richtung und Amplitude (Schmitt et al. 2014). Je nach Wahl können unterschiedliche räumliche Details der Bilder kombiniert und hervorgehoben werden. Die modifizierten Curvelet-Koeffizienten werden abschließend wieder in den Bildraum rücktransformiert (Nencini et al. 2007).

Model-based Approaches

Die Gruppe der modellbasierten Fusionsalgorithmen ist groß und vielseitig. Mal geht es um die Verstärkung von Kanten, mal um das Füllen von wetterbedingten Lücken in Beobachtungszeitreihen.

Das Markov-Random-Field-(MRF-)Modell wird zur Detektion von Kanten in Bildern eingesetzt. Bei diesem stehen die Pixeldaten fest und nur das Kantenmodell wird aktualisiert. Neben dem Pixelgitter des Bilds wird ein dazwischenliegendes Grenzgitter erstellt, welches Diskontinuitäten zwischen Pixelstellen ermöglicht. Das Markov-Random-Field wird über beide Gitter definiert, ebenso wie eine Nachbarschaft für alle Gitterpunkte. Das bedeutet, dass jede Stelle des Grenzgitters von den Werten der Pixelstellen und der Grenzgitterstellen in ihrer Umgebung abhängig ist. Für jeden Punkt werden also die Wertunterschiede der Punkte der Nachbarschaft betrachtet. Mit einem Kantenfilter werden Kanten zwischen Pixeln mit großer Disparität detektiert. Weiterhin wird die Anzahl der unvollständigen und nicht eindeutig lokalisierten Kanten gezählt. Diese verschlechtern die Kantendarstellung und werden deshalb durch einen Multiplikator kontrolliert und optimiert (Wright 1999). Um mehrere Bilder zu fusionieren, wird das MRF über beide Bilder erweitert, da angenommen wird, dass, wenn eine Kante in einem Bild existiert, wahrscheinlich ist, dass sie auch in den anderen Bildern des gleichen Gebiets auftritt. Jedes Bild wird einer Kantendetektion nach oben beschriebenem Algorithmus unterzogen. Über den Fusionsterm, der über dieselbe Kantenstelle in allen zu fusionierenden Bildern definiert ist, werden die Kanten in das fusionierte Bild übernommen (Wright 1999). Dem gegenüber steht der Ansatz des Non-Local-Means-Filters, welcher u. a. bei der Speckle-Reduktion in Radaraufnahmen zur Anwendung kommt (Ullmann et al. 2014). Dieser besagt eben nicht, dass die gleiche Kante immer am gleichen Ort vorkommen muss, sondern dass eine Kante,

z. B. der Übergang zwischen Wasser und Land, an verschiedensten Stellen im Bild ähnlich auftreten kann, und fusioniert deshalb ähnliche Bereiche unabhängig von ihrer Lage (daher non-local).

In einer Studie schlagen Golipour et al. (2016) eine neue spektral-räumliche Klassifizierungsmethode für Hyperspektralbilder vor, die auf der Integration von hierarchischen Segmentierungsergebnissen in räumliche Markov-Zufallsfeld-Prioritäten im Bayes'schen Rahmen beruht. Weiterhin wurde eine lernbasierte Superresolution-Fusionsmethode vorgeschlagen, die die swath-width und die spektralen Eigenschaften von Landsat TM/Enhanced TM Plus (ETM+) und die räumliche Auflösung von SPOT5 kombiniert. Die Klassifizierungsleistung kann von einer geeigneten Merkmalsfusion profitieren (Song et al. 2015). Eine weitere Technik stellt eine auf Softmax-Regression basierende Methode zur Merkmalsfusion vor. Dabei werden unterschiedliche Gewichte für verschiedene Merkmale gelernt. Bei dieser Methode werden Ähnlichkeitsmaße von Objekt zu Klasse und die bedingten Wahrscheinlichkeiten, dass jedes Objekt zu verschiedenen Klassen gehört, geschätzt. Darüber hinaus wird eine Näherungsmethode zur Berechnung der Klasse-zu-Klasse-Ähnlichkeiten zwischen verschiedenen Klassen eingeführt. Schließlich wird ein Support-Vector-Machine-Klassifikator unter Verwendung der erhaltenen Fusions- und Ähnlichkeitsinformationen erstellt (Bai et al. 2015).

Die meisten Algorithmen für die raumzeitliche Fusion verarbeiten eine Gruppe von Pixeln in einem Fenster (Moving Window), das jedes Pixel umgibt, um die entsprechenden räumlichen, spektralen und zeitlichen Gewichte zu berechnen. Ein sehr beliebtes raumzeitliches Fusionsverfahren, das die Grundlage für viele andere Fusionsverfahren bildet, ist das räumliche und zeitliche adaptive Reflexionsfusionsmodell (STARFM). Der STARFM-Algorithmus erzeugt die Fusionsdaten durch eine gewichtete Summe der spektral ähnlichen Nachbarschaftsinformationen aus den Bildern mit hoher räumlicher Auflösung und den Bildern mit hoher zeitlicher Frequenz (Gao et al. 2006). STARFM wird überwiegend verwendet, um die raumzeitlichen Eigenschaften von Bilddatensätzen, die von den Sensoren Landsat und Moderate Resolution Imaging Spectroradiometer (MODIS) sowie von geostationären Plattformen

erfasst wurden, optimal zu nutzen. Darüber hinaus wurden in der Zwischenzeit einige verbesserte Algorithmen auf der Grundlage raumzeitlicher Filter entwickelt. Hilker et al. (2009) schlugen so den räumlich-zeitlich adaptiven Algorithmus für die Kartierung von Reflexionsänderungen – Spatial Temporal Adaptive Algorithm for Mapping Reflectance Change (STAARCH) – vor, um sehr detaillierte räumliche und zeitliche Muster in Landbedeckungsveränderungen zu erkennen. Dieser nutzt dabei die Tasseled-Cap-Transformation (Crist & Cicone 1984). Zhu et al. (2010) entwickelten ein erweitertes STARFM-Modell, Enhanced STARFM (ESTARFM), welches einen Umrechnungskoeffizienten anwendet, um die zeitlichen Unterschiede zwischen Bildern mit feiner und grober Auflösung zu bewerten.

Um diese Verfahren weiter zu verbessern, haben Studien vorgeschlagen, Methoden des maschinellen Lernens einzusetzen, um ähnliche Pixel anhand ihrer Klassen zu identifizieren (Knauer et al. 2016). Der auf raumzeitlichen Filtern basierende Fusionsrahmen war bisher eine sehr beliebte und häufig angewandte Kategorie der spatio-temporalen Fusionsansätze. Obwohl diese in vielerlei Hinsicht verbessert wurden, weist das auf raumzeitlichen Filtern basierende Fusionsverfahren immer noch einige Defizite auf, welche stark mit der räumlichen und zeitlichen Variabilität der Bodenbedeckung zusammenhängen.

Cheng et al. (2017) schlugen daraufhin den STNLFFM-Algorithmus vor, der mehrere Verbesserungen an den STARFM- und ESTARFM-Algorithmen vornimmt. Der STNLFFM-Algorithmus nutzt dabei zwei hochauflösende Bilder, welche vom selben Sensor zu unterschiedlichen Zeitpunkten aufgenommen wurden. In das Vorhersagemodell werden so zwei Regressionskoeffizienten eingeführt, welche durch die Reflexionsveränderungen zwischen Referenz und Vorhersagedatum bestimmt werden. Dadurch wird die Transformationsbeziehung zwischen den beiden Eingangsbildern genauer beschrieben und damit die Vorhersagefähigkeit zu optimieren. Weiterhin führt STNLFFM die Idee der nichtlokalen Filterung ein, die den hohen Grad an Redundanz in der Bildsequenz ausnutzt, um eine genauere und robustere Vorhersage zu erreichen. Darüber hinaus verwendet STNLFFM eine einfache Methode zur Berech-

nung der Gewichte, welche die Effizienz der Berechnungen verbessert und die Störung durch Bildrauschen reduziert. Schließlich löst STNLFFM das Problem der zeitlichen Differenzmessung bei der Suche nach ähnlichen Pixeln und verbessert die Genauigkeit der Auswahl ähnlicher Pixel.

Hypercomplex Bases

Hyperkomplexe Basen spielen auch im Bereich der merkmalsbasierten Datenfusion eine wichtige Rolle. Spektrale Merkmale liegen häufig in Form sogenannter „Normalized Differences“ (Henrich et al. 2012) mit einem normierten Wertebereich $]-1, +1[$ vor. Der normierte Wertebereich bietet viele Vorteile hinsichtlich radiometrischer Abtastung, Visualisierung und sogar der Verarbeitung mit Methoden des maschinellen Lernens. Support Vector Machines fordern beispielsweise einen normierten Wertebereich. Um diese Eigenschaften jedoch auch nach der Fusion beizubehalten, bedarf es der integralen Kennaugh-Elemente (Schmitt & Wendleder 2016). Wie die Kennaugh-Elemente der pixelbasierten Methoden besteht dieser Fusionsansatz wieder aus Integral Kennaugh sk und Differential Kennaugh dk , wobei eine Normalisierung notwendig wird (Formel 4).

$$sk = \frac{k_a + k_b}{1 + k_a \cdot k_b} \in]-1, +1[$$

$$dk = \frac{k_a - k_b}{1 - k_a \cdot k_b} \in]-1, +1[\quad (\text{Formel 4})$$

Die Anwendung bleibt nicht auf Kennaugh- oder Kennaugh-like-Elemente beschränkt, sondern kann auf jeden beliebigen Index mit diesem normierten Wertebereich ausgedehnt werden, wie das spätere Beispiel zeigen wird.

3.3 ENTSCHEIDUNGSEBENE

Die Fusion auf Entscheidungs- oder Interpretationsebene findet auf der höchsten Verarbeitungsstufe statt, wie aus Abbildung 1 abzuleiten ist. Die einzelnen Bilder werden separat und unabhängig voneinander verarbeitet und einer Informationsextraktion unterzogen. Die so aus den verschiedenen Bildern gewonnenen Informationen werden dann über Entscheidungsregeln kombiniert (Pohl & Van Genderen 1998). Dieser Prozess ist in Abbildung 2 dargestellt. Eine weitere Unterteilung in Gruppen wird hier nicht mehr vorgenommen, weil die Ver-

fahren lediglich in der Art der Kombination der bereits getroffenen Entscheidung variieren.

Schollerer et al. (2022) haben kürzlich den Prototyp eines Prozessors zur vollautomatischen und flächendeckenden Baufallerkundung vorgestellt, der Sentinel-1 und Sentinel-2 wegen der wolkenbedingt höchst unterschiedlichen zeitlichen Abtastung getrennt ausgewertet und dann erst die erkannten Neubauten sensorübergreifend abgleicht. Diese logische UND-Verknüpfung kann durch Fuzzy Logic verfeinert werden. Fuzzy Decision Rules kennen nicht nur eine binäre Entscheidung 0 oder 1, sondern einen kontinuierlichen Wahrscheinlichkeitsbereich von unmöglich (0) bis sicher (1). Diese Fuzzy-Sets der Eingangsdaten werden mit relativen Gewichten normalisiert, um den Einfluss unzuverlässiger Daten zu verringern und das Gewicht der zuverlässigen Information zu erhöhen. Jetzt wird der Kombinationsoperator angewendet, welcher das globale Vertrauen der Quelle für die Klasse, den Gewichtungparameter und ein Element des Fuzzy-Sets enthält (Fauvel et al. 2006, Ghassemian 2016). Mithilfe dieser Fuzzy-Kombinationsregel wird sichergestellt, dass für jede Klasse nur zuverlässige Quellen verwendet werden und die Fusion lokal an den Kontext angepasst ist, da diejenige Quelle bevorzugt wird, die lokal am sichersten ist. Den letzten Schritt stellt die endgültige Entscheidung der Klasse dar. Diese wird getroffen, indem diejenige Klasse gewählt wird, welche den größten resultierenden Zugehörigkeitswert aufweist (Fauvel et al. 2006, Ghassemian 2016). Des Weiteren wurde kürzlich eine von Pogoda et al. (2022) auf multikriterieller Entscheidungsanalyse (MCDA) und dem Analytical Hierarchy Process (AHP) (Saaty 1977) basierende Studie durchgeführt, welche flächendeckend in der AVZ der Nordsee Habitatsflächen für die Wiederansiedlung der europäischen Auster indiziert. Es wurden mehrere Bewertungskriterien eingeführt, die auf der AHP-Methode basieren, um die Gewichte einer Reihe von Eingangsdaten zu schätzen. Die AHP-Methode ist eine der beliebtesten Methoden, die im Rahmen des MCDA-Ansatzes verwendet werden. Der AHP-Algorithmus ermöglicht es den Anwendern, das relative Gewicht der einzelnen Elemente der Hierarchie (Kriterien und Entscheidungsalternativen) anhand von paarweisen Vergleichen zu bewerten.

Einen ähnlichen Ansatz verfolgen auch Schmitt et al. (2018), indem sie aus multiplen Aufnahmen derselben Stadt aus verschiedenen Blickwinkeln polarimetrische und strukturelle Information ableiten und die jeweilige Wahrscheinlichkeit des Auftretens einer informellen Siedlung mithilfe der Histogramm-Klassifikation schätzen. Die Zusammenführung der einzelnen Wahrscheinlichkeitslayer erfolgt durch ein neu eingeführtes Ähnlichkeitsmaß, welches die kombinierte Wahrscheinlichkeit ausgibt. Es muss jedoch nicht immer um die Zuordnung nominaler Klassen gehen. Auch der Koeffizientenabgleich temporaler Regressionen ist möglich. Wendleder et al. (2021) evaluieren die zeitgleiche Ableitung von Gletscherseen auf dem Baltoro im Karakorum mit optischen (Sentinel-2 und PlanetScope) und Radar-Sensoren (Sentinel-1 und TerraSAR-X). Für jeden Sensor entsteht zwar eine eigene Kartierung, jedoch werden die geschätzten Seenflächen multisensoral angepasst, da bekannt ist, dass einige Sensoren die Seenfläche unter-, andere sie wiederum überschätzen.

Betram et al. (2016) nutzten wetter- und tageszeitunabhängige Multisensor- und multitemporale SAR-Daten, die mit dem Multi-SAR-System verarbeitet wurden, um die Wasserdynamik des Tabalak-Sees langfristig zu überwachen. Dabei wurden Sentinel-1A, TerraSAR-X (TSX), ALOS PAL-SAR-1/2, Envisat ASAR, RADARSAT-1/2, und ERS-1/2 Daten verwendet. Diese wurden mit dem Multi-SAR-System verarbeitet, das Orthorektifizierung, radiometrische Kalibrierung, Normalisierung, Kennaugh-Zerlegung sowie weitere Bildverbesserungen umfasst. Das MultiSAR-System vereinheitlicht dabei alle Szenen in einem einheitlichen Format (Schmitt et al. 2015, Huber et al. 2004). Am Ende der Fusion steht für jeden Sensor und jeden Aufnahmezeitpunkt nur noch eine Wassermaske mit der binären Entscheidung „Wasser ja/nein“.

3.4 HYBRID

Wenn das gewünschte Ergebnis nicht mit einer einzelnen Fusionsmethode erreicht werden kann, besteht die Möglichkeit, mehrere Methoden zu kombinieren (Pohl & Van Genderen 1998). Hybride Methoden nutzen so die Vorteile der einzelnen Techniken (Ghassemian 2016, Zhang 2010). Vlaiszadeh & Ghassemian (2012) schlagen beispielsweise eine Fusionsmethode vor, welche die

IHS- (auf Pixel Level) und die Curvelet-Fusionstechnik (auf Feature Level) kombiniert. Die zu fusionierenden Bilder werden vorverarbeitet und drei Bänder werden ausgewählt. Wie bei der IHS-Fusionsmethode wird das RGB-Bild in den IHS-Farbraum transformiert und ein Histogrammabgleich des räumlich hochaufgelösten PAN-Bilds mit der Intensitätskomponente des IHS-Bilds durchgeführt. Das panchromatische Bild und die I-Komponente werden in die Curvelet-Koeffizienten zerlegt. Anschließend wird das detailreiche Bild in das Intensitätselement eingefügt. Das fusionierte Bild wird neu zusammengesetzt und zurück in den RGB-Farbraum transformiert (Vlaizadeh & Ghassemian 2012). Dong et al. (2015) führen einen ähnlichen Ansatz an, bei dem IHS- und Curvelet-Transformation kombiniert und dazu die Fusionsregeln der Standardabweichungsmethode angewandt werden. Weitere übergreifende Methoden sind selbstverständlich denkbar und sicherlich längst in Gebrauch.

4 EXEMPLARISCHE FUSION AUF PIXEL, FEATURE UND DECISION LEVEL

Zur Veranschaulichung der hauptsächlich drei Fusionsebenen wird im Folgenden die Fusion einer Sentinel-1-Aufnahme vom 01.06.2021 mit einer Sentinel-2-Aufnahme

me vom 02.06.2021 über dem Hollerner See (48° 17' N, 11° 36' O) nördlich von München zur Ableitung der Wasseroberfläche gezeigt. Abbildung 5 veranschaulicht die vier von Sentinel-1 verfügbaren polarimetrischen Kanäle. Offensichtlich ist der Informationsgehalt der beiden Amplituden sehr ähnlich, während die Phasenmessungen komplett zufällig erscheinen. Bei Sentinel-2 in Abbildung 6 sehen alle vier Spektralkanäle sehr ähnlich aus, lediglich Infrarot erscheint – abgesehen von der Wasseroberfläche – etwas heller. Nun gilt es, diese Synergien zu nutzen und das Rauschen zu separieren.

Fusioniert man die beiden Aufnahmen auf Pixelebene mithilfe der hyperkomplexen Basen, entstehen acht Kennaugh-like-Elemente, von denen je drei in Abbildung 7 dargestellt sind. Aufgrund der Orthogonalität gehen weder Informationen verloren noch werden Abhängigkeiten durch die Transformation induziert. Der resultierende Merkmalsraum umfasst folglich acht Dimensionen und liefert die ebenso in Abbildung 7 rechts gezeichnete mittlere Signatur für Wasseroberflächen. Die Signatur enthält die komplette Information, also auch für die Abgrenzung von Wasseroberflächen nutzlose Kanäle. Im Gegenzug sind aber auch sämtliche Informationen zu anderen Landbedeckungsklassen vorhanden, welche zur

Abgrenzung eine immens wichtige Rolle spielen. Dank der möglichen Normierung der Kennaugh-Elemente kann die radiometrische Abtastung problemlos auf 8 bit reduziert werden (Schmitt et al. 2020).

Zur Fusion auf Merkmalsebene werden vorab die einzelnen Kanäle von Sentinel-1 und Sentinel-2 getrennt und in für die Ableitung von Wasseroberflächen aussagekräftige Indizes umgewandelt. Für Radaraufnahmen bietet sich die Gesamtintensität K_0 an, in der Wasseroberflächen aufgrund der spiegelnden Reflexion sehr dunkel erscheinen. Mit dem typischen Grenzwert von $g_w = -17$ dB ≈ 0.02 für Wasseroberflächen kann dann ein Radarwasserindex RWI entworfen werden, der einen normierten Wertebereich aufweist und für Wasser positive Werte ausweist (Formel 5).

$$RWI = \frac{g_w - K_0}{g_w + K_0} \quad (\text{Formel 5})$$

Für optische Aufnahmen hat sich der Normalized Difference Water Index (NDWI) nach McFeeters (1996) etabliert (Formel 6).

$$NDWI = \frac{\text{Grün} - \text{NIR}}{\text{Grün} + \text{NIR}} \quad (\text{Formel 6})$$




Abbildung 5: Die vier Polarisationskanäle einer typischen Sentinel-1-Aufnahme über Mitteleuropa (© ESA 2021)




Abbildung 6: Die vier Spektralkanäle mit 10-m-Pixeln einer Sentinel-2-Aufnahme (© ESA 2021)




Abbildung 7: Fusion auf Pixelebene: Je drei der aus Sentinel-1 und Sentinel-2 (© ESA 2021) auf hyperkomplexen Basen fusionierten Kennaugh-like-Elemente aus den Abbildungen 5 und 6 in RGB-Darstellung sowie die Verteilung im Merkmalsraum mit etwa 28.000 Einträgen aus je 256 möglichen Werten (8 bit)

Zwar können die Werte der Indizes direkt mit Wasser in Verbindung gebracht werden, jedoch gehen bei der Beschränkung auf die Indizes zwangsweise Informationen verloren. Die Indizes können nur informationserhaltend auf hyperkomplexen Basen zu integralen Kennaugh-like-Elemente sk und dk fusioniert werden (siehe Abbildung 8). Die Summe sk ermöglicht eine ganz klare Unterscheidung von Wasser und Land. Die Differenz dk visualisiert alle Flächen, bei denen die Indizes nicht übereinstimmen. Im Hollerner See ist das vor allem durch die Bathymetrie begründet, die sich in der optischen Aufnahme durchpaust, aber in der Radaraufnahme keinerlei Rolle spielt, weil Mikrowellen an der Wasseroberfläche streuen und somit nicht in das Wasser eindringen. Deshalb weichen vor allem die Uferbereiche stark ab. Der Scatterplot zeigt für sk eine glatte Kurve mit eindeutigem Modus, die für die Klassifikation mit herkömmlichen Verfahren (Schwellenwert, Maximum Likelihood etc.) hergenommen werden kann. Das Histogramm von dk hingegen ist sehr rau, was auf das erhöhte Rauschen in diesem Kanal hinweist. Die Fusion auf Merkmalsebene liefert unbestritten eindrucksvolle und vor allem einfach interpretierbare Indizes, erfordert jedoch auch eine Menge Vorwissen über das Reflexionsverhalten der untersuchten Oberflächen in den Aufnahmen der eingesetzten Sensoren.

Auf Entscheidungsebene vereinfacht sich die Fusion weiter: Von Sentinel-1 und Sentinel-2 kommt pro Pixel nur noch eine binäre Aussage „Wasser ja/nein“ oder maximal eine Wahrscheinlichkeitsangabe zwischen null und eins. Eine feinere Analyse ist nicht mehr möglich. Daher müssen die Ver-

fahren zur Ableitung der Wassermaske bereits zuverlässig funktionieren. Flächenmäßige Analysen der Übereinstimmung, wie z. B. der Jaccard-Index oder „Intersection over Union“ genannt, der den Anteil gemeinsam als Wasser erkannter Fläche ins Verhältnis zur wenigstens von einem Sensor erkannten Wasserfläche setzt, können dafür direkt auf dem Fusionsergebnis ausgeführt werden (Abbildung 9). Das Decision Level eignet sich vor allem für Prozessoren, die dem Nutzer lediglich die jeweiligen Endergebnisse z. B. in Form von Wasserpolygonen und dazugehörige Genauigkeitsabschätzungen bereitstellen, aber dafür auch vollautomatisch arbeiten.

5 DISKUSSION

Jedes Verfahren der Bilddatenfusion hat nicht nur seine eigene Algorithmik und Anwendung, sondern teils sehr spezielle Vorzüge und ebenso Nachteile. Diese Charakteristika sollen im Folgenden anhand gebräuchlicher Qualitätskriterien diskutiert werden. Für die Beurteilung der verbesserten räumlichen Auflösung kommen die gleichen Qualitätsmaße infrage, wie sie bei der Beurteilung räumlicher Filter längst eingesetzt werden: Erhaltung der mittleren Helligkeit, Glättung homogener Bereiche, Erhaltung der Kantenstärke und -richtung, Erhaltung der Krümmungsstärke und -richtung (Schmitt 2016). Für die Evaluierung der Fusion im Spektralbereich haben sich eigene Verfahren etabliert, die in Tabelle 2 aufgeführt sind. Generell zielen diese Maßzahlen darauf ab, entweder die Verzerrung einer bestimmten Eigenschaft zu bemessen (z. B. des Farbtons) oder den Informationsgehalt abzuschätzen (z. B. Entropie). Wel-

che Eigenschaft nun ausschlaggebend ist, hängt wiederum von der Anwendung ab.

5.1 PIXEL LEVEL

Da auf Pixel Level (fast) die direkten Messungen kombiniert werden, ist der Informationsverlust auf dieser Fusionsebene minimal (Pohl & Van Genderen 1998). Andere Quellen berichten, dass die Genauigkeit der Fusion hier am höchsten ist (Wenbo et al. 2008), was sicher damit einhergeht, dass die in Tabelle 2 gelisteten Maße einfach berechnet und die Abweichungen damit gut evaluiert werden können. Auch sollen Artefakte bei Fusion auf Pixelebene weit weniger auftreten als bei Fusion auf höheren Verarbeitungsstufen (Elmasry et al. 2020). Aufgrund ihrer Einfachheit sind die Methoden flexibel einsetzbar (Basaeed et al. 2012, Princess et al. 2014), was sich als ein Grund der Vielzahl bereits publizierten Verfahren darstellt. Im Grunde werden „mehr Layer“ mit „mehr Information“ gleichgesetzt, was die Verwertbarkeit der Daten erhöht (Pandit & Bhiwani 2015). Mögliche Fehler bei der Fusion auf Pixelebene sind störende Farbränder bei der mangelhaften Koregistrierung der Farbbänder oder Histogrammanpassung (Pohl & Van Genderen 1998), die schon bei einem Versatz um den Bruchteil eines Pixels auftreten können (Ghassemian 2016). Die Fusion auf Pixel Level bedingt immer eine Neuabstimmung der Bilddaten und somit eine räumliche Interpolation mit weiteren Einflüssen auf die Bildqualität (Ghassemian 2016, Pohl & Van Genderen 1998). Die meist verwendete bikubische Interpolation neigt zu Überschwingern an kontrastreichen Kanten, wie sie beispielsweise in Radarbildern von

Name	Beschreibung	Zweck	Literatur
Spectral Angle Mapper (SAM) Relative Average Spectral Error (RASE)	Winkel bzw. relative Abweichung zwischen Pixelwerten im Spektralraum	Verzerrung des Farbtons	Wei et al. 2015a Huang et al. 2014
Universal Image Quality Index (UIQI)	Kombiniert Helligkeitsverzerrung, Kontrastverzerrung und Korrelationsverlust	Verzerrung der spektralen Signatur	Fonseca et al. 2011 Sanli et al. 2013
Entropy (E) Similarity (S) to Uniform Distribution	Misst die Abweichung des Histogramms von einer Gleichverteilung	Informationsgehalt	Rao et al. 2014 Schmitt et al. 2020
Entropy-Alpha-Ebene	Visualisiert die Verteilung polarimetrischer Parameter	Polarimetrischer Informationsgehalt	Schmitt & Wendleder 2018
Correlation Coefficient (CC)	Korrelation des fusionierten Bilds mit den Originalen	Ähnlichkeit der Bildinhalte	Pandit & Bhiwani 2015
Average Gradient (AG)	Misst die Veränderung der Bildtextur und Detailinformationen	Bewertung der räumlichen Auflösung	Fonseca et al. 2011 Rao et al. 2014
Peak Signal to Noise Ratio (PSNR)	Verhältnis zwischen maximalen Signalwert und dem Rauschen via Mean Square Error (MSE)	Bewertung der radiometrischen Verzerrung	Damera-Venkata et al. 2000 Canga et al. 2005 Yuhendra et al. 2012

Tabelle 2: Gebräuchliche Qualitätsmaßstäbe bei der Bilddatenfusion

Siedlungen recht häufig vorkommen. Die lineare Interpolation bedingt stets eine Glättung der Ausgangsdaten. Die Nächster-Nachbar-Interpolation erhält zwar den Kontrast, führt aber zu einem räumlichen Versatz von bis zu einem halben Pixel. Daher wird empfohlen, möglichst auf Rohdaten zurückzugreifen und die Aufnahmeparameter des Sensors mit zu berücksichtigen (Pohl & Van Genderen 1998). Die auf Pixel Level zu verarbeitende Datenmenge ist sehr groß (Pandit & Bhiwani 2015, Pohl & Van Genderen 1998), jedoch mit heutigen Methoden der Bildverarbeitung durchaus zu bewältigen. Lediglich die Zusammenführung sehr heterogener Daten stellt heutzutage noch eine Herausforderung dar (Pohl & Van Genderen 1998). Hinsichtlich heterogener Daten sei auch auf die Rauschempfindlichkeit der Fusion auf Pixel Level hingewiesen (Princess et al. 2014). Da auf Pixel Level noch keine semantische Information vorliegt, lässt sich Rauschen noch nicht von Information trennen. Eine Ausnahme bilden da die Kennaugh-Elemente der hyperkomplexen Basen, die diese Trennung informationstheoretisch vornehmen. Da das Ziel aller pixelbasierten Fusionsverfahren wieder ein Bild ist, sind die Ausgabebilder der Fusion auf Pixelebene meist qualitativ hoch-

wertiger als bei anderen Verfahren mit anderem Fokus (Pandit & Bhiwani 2015). Daher werden Fusionen auf Pixel Level gerne für Visualisierungszwecke hergenommen.

Die Brovey-Methode ist rein auf RGB-Bilder ausgelegt und erfordert einen erfahrenen Bildbearbeiter zur korrekten Wahl der Parameter, da sonst sehr schnell radiometrische Verzerrungen auftreten (Pandit & Bhiwani 2015). Bei Qualitätsmaßen wie SAM und RASE (siehe Tabelle 2) schneidet diese Methode nicht besonders gut ab, weshalb sich die radiometrische Signatur in den fusionierten Bildern nicht mehr zuverlässig evaluieren lässt (Ha et al. 2012). Auch müssen die Eingangsbilder bereits stark korreliert sein (CC in Tabelle 2), damit die Methode anwendbar ist (Ghassemian 2016). Dafür ist der Rechenbedarf bei lediglich drei arithmetischen Operationen gering und somit ein hoher Datendurchsatz gewährleistet (Gharbia et al. 2014, Jiang et al. 2011). Die Methode wurde entwickelt, um den Kontrast am oberen und unteren Ende des Histogramms eines Bilds visuell zu erhöhen. Damit können mit der Brovey Transformation visuell ansprechende Bilder geschaffen werden, da diese einen höheren Kontrastgrad aufweisen (Ha et al. 2012, Nikolakopoulos 2008). Beispiels-

weise kann der Kontrast in Schatten, Wasser und Bereichen mit hohem Reflexionsgrad, wie z. B. in Städten, erhöht werden (Nicolakopoulos 2008). Die Wasser-Land-Grenzen sind im fusionierten Bild gut definiert (Pohl & Van Genderen 1998). Trotz dieser Einschränkungen bezüglich der Radiometrie wird die Brovey-Transformation häufig als Benchmark für anderen Fusionsmethoden herangezogen (Gharbia et al. 2014). Haupteinsatzzweck ist die Erhöhung der räumlichen Auflösung bzw. des Schärfegrads durch Fusion mit einem panchromatischen Kanal (Ghassemian 2016) oder mit monofrequenten Radaraufnahmen (Gharbia et al. 2014). Dabei bleibt die spektrale Information des Eingangsbilds erhalten, während die Textur von SAR hinzugefügt wird (Pohl & Van Genderen 1998). Mit dieser einfachen Fusion können die Eigenschaften verschiedener Sensoren kombiniert werden (Pandit & Bhiwani 2015).

Auch die IHS-Fusionsmethode ist einfach und schnell zu implementieren (Ghassemian 2016, Jiang et al. 2011). Die IHS-Technik bildet den RGB-Farbraum adäquat ab und erhält somit besser die spektralen Eigenschaften (Pohl & Van Genderen 1998). Wegen der Beschränkung auf drei Kanäle (Pandit & Bhiwani 2015) muss die

Methode bei multispektralen Aufnahmen auf Kanalgruppen mehrfach angewendet werden (Sanli et al. 2016). Eine Verallgemeinerung der IHS-Fusionsmethode auf einen vierdimensionalen Farbraum ermöglicht die Verarbeitung von typischen Vierkanal-Luftbildern oder den 10-m-Bändern von Sentinel-2 (Zhang 2010). Obwohl die IHS-Methode zu den Component-Substitution-Methoden zählt, wird wie bei Brovey eine hohe Korrelation zwischen den Eingangsbildern vorausgesetzt, um Farbverfälschungen zu vermeiden (Ghassemian 2016). Durch Anpassung des panchromatischen Kanals an die Intensitätskomponente oder durch Streckung der H- und S-Komponente können diese Verzerrungen jedoch in diesem Fall verringert werden (Fonseca et al. 2011). Beides beeinflusst jedoch wie-

derum die Vergleichbarkeit der Signaturen vor und nach der Fusion (Ha et al. 2012). Aufgrund der unterschiedlichen Wertebereiche der IHS-Layer ist eine Kombination mit Fusionsverfahren im Frequenzraum ausgeschlossen (Shi et al. 2005).

Ähnlich wie Brovey wird auch die IHS-Methode dazu verwendet, multispektrale mit panchromatischen Bildern oder Radarbildern zu fusionieren (Gupta & Mehra 2016, Sanli et al. 2016). Gegenüber heterogenen Datensätzen verhält sich die IHS-Methode jedoch deutlich robuster (Pohl & Van Genderen 1998).

Beide bereits diskutierten Verfahren dienen vornehmlich der Erzeugung visuell ansprechender Bilder, ohne zu sehr auf radiometrische Eigenschaften zu achten. Die Fusion auf hyperkomplexen Basen hingegen

erhält die ursprüngliche Signatur, transformiert diese jedoch auf neue, orthogonale Basen, die nur noch aus einer Gesamtintensität (ähnlich dem panchromatischen Kanal) und vielen Intensitätsunterschieden bestehen. Prinzipiell kann jede beliebige Anzahl an Kanälen auf hyperkomplexe Basen gebracht werden, wobei sich Zweierpotenzen besonders anbieten, da hier keine Redundanzen zu erwarten sind (Schmitt et al. 2020). Signal und Rauschen werden bestmöglich getrennt, sodass die Gesamtintensität in der Regel ein räumlich hochaufgelöstes, scharfes Bild enthält und mit jedem weiteren Kennaugh-Element die Aussagekraft ähnlich einer Hauptkomponentenzerlegung weiter abnimmt.

Die Fusion aus mehreren Quellen umfasst beispielsweise das SAR-Sharpenering




Abbildung 8: Fusion auf Merkmalsebene: Integral Kennaugh sk und Differential Kennaugh dk aus dem Radar Water Index von Sentinel-1 (© ESA 2021) bereits Multi-scale Multi-Looking gefiltert und den Normalized Difference Water Index (NDWI) von Sentinel-2 (© ESA 2021) sowie ein Scatterplot samt Randverteilungen und der typischen Lage von Wasserpixeln im Merkmalsraum. Nur noch etwa 7.000 Messungen mit einer sinnvollen Abtastung von etwa 20 Werten sind vorhanden. Die Klassifikation kann alleine auf Basis der Werte in sk erfolgen, nachdem das Rauschen in dk separiert worden ist.

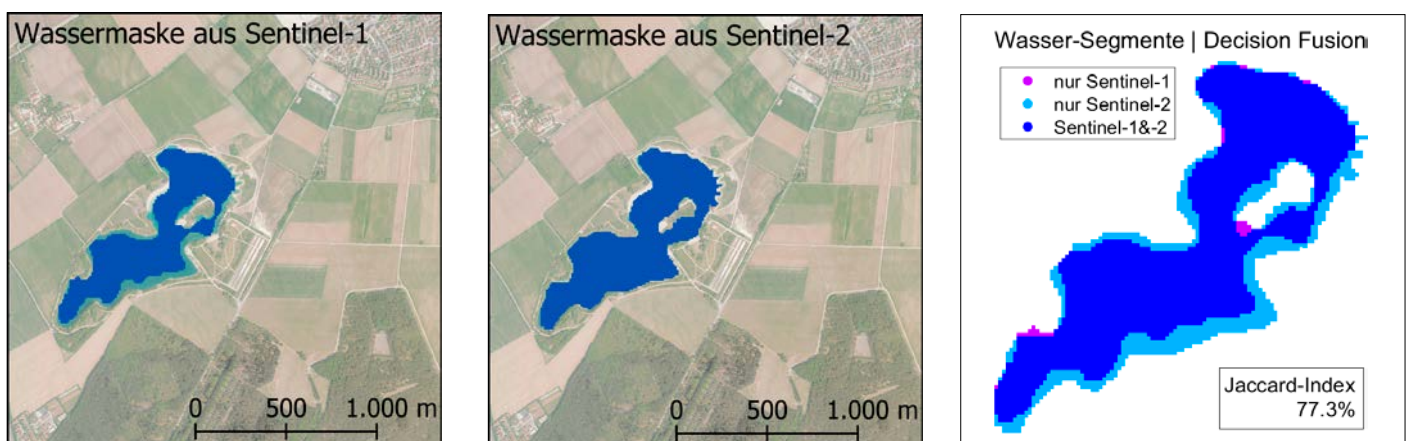


Abbildung 9: Fusion auf Entscheidungsebene: Die beiden binären Wassermasken aus Sentinel-1 und Sentinel-2 werden überlagert und fusioniert zu einer gemeinsamen Wassermaske aus 2.857 Pixeln mit lediglich vier Abstufungen: nur Sentinel-1, nur Sentinel-2, beide oder keiner. Die flächenmäßige Übereinstimmung nach Jaccard-Index (Intersection over Union) beträgt in diesem Beispiel 77,3%. Im Hintergrund ist das Digitale Orthophoto DOP80 der Bayerischen Vermessungsverwaltung zu sehen (© BVV 2022).

(Schmitt & Wendleder 2016), die polarimetrische Fusion, die spektrale Fusion und die Fusion von optischen und SAR-Daten (Schmitt & Wendleder 2018). Mithilfe der multitemporalen Fusion können Veränderungen detektiert und Zeitreihenanalysen durchgeführt werden (Schmitt et al. 2020). Als Nachteil der hyperkomplexen Basen kann angesehen werden, dass die Ergebnisbilder eben nicht den gewohnten RGB- oder CIR-Ansichten entsprechen. Dafür wurde bereits nachgewiesen, dass eine Steigerung des Informationsgehalts stattfindet (Entropy-Alpha-Ebene in Tabelle 2), die auch mit Reduktion der radiometrischen Abtastung erhalten bleibt (S in Tabelle 2). Somit eignet sich diese Fusionsmethode hervorragend für die Fusion großer Datenmengen, die anschließend mit modernen, vollautomatischen Interpretationsmethoden aus dem Bereich des maschinellen Lernens ausgewertet werden sollen.

5.2 FEATURE LEVEL

Die Fusion auf Feature Level setzt voraus, dass die Features bereits berechnet worden sind. Dieser Schritt verringert in der Regel die Datenmenge ganz beträchtlich. Wenn wie im veranschaulichten Beispiel statt der acht Eingangskanäle nur noch zwei Features (RWI und NDWI) betrachtet werden müssen, ist klar, dass sich die Datenmenge auf ein Viertel reduziert. Da beide Features bereits semantische Information enthalten, wird die Zuverlässigkeit der Fusion auf Merkmalebene generell als höher eingestuft (Basaeed et al. 2012, Pandit & Bhiwani 2015). Da es sich um bereits weiterverarbeitete Daten handelt, spielen auch die Sensorparameter anders als bei der Fusion auf Pixel Level eine untergeordnete Rolle (Pandit & Bhiwani 2015). Auch Fehler in den Eingangsdaten, wie eine unzureichende Koregistrierung, wirken sich deutlich weniger aus (Princess et al. 2014). Als Nachteil muss angeführt werden, dass die Fusion auf Feature Level eine zuverlässige Extraktion von Merkmalen aus den Sensordaten erfordert (Pohl & Van Genderen 1998). Die Extraktionsmethoden sind extrem abhängig von den Charakteristiken der einzelnen Sensoren (Zhang 2010), wie z. B. Wasserflächen aus optischen Aufnahmen oder aus Radar. Die Beschränkung auf einzelne Merkmale bedingt zudem notwendigerweise einen Informationsverlust (Pohl & Van Genderen 1998, Princess et al. 2014),

der zwar für die konkrete Anwendung unerheblich ist, jedoch andere Anwendungen möglicherweise unterbindet. Aus dem NDWI kann beispielsweise keine Information über den Zustand der Vegetation abgeleitet werden, aus den auf Pixel Level fusionierten Daten schon. Somit muss schon bei der Auswahl der Merkmale gesichert sein, dass diese Merkmale für die gewünschte Anwendung aussagekräftig sind und ihre Ableitung auch immer konsistent möglich ist. Wenn ein als Merkmal identifizierter Layer beispielsweise nur Rauschen enthält, paust sich dieses Rauschen direkt auf den fusionierten Ergebnislayer durch. Dieser Ansatz wird vor allem zu Klassifizierungszwecken eingesetzt und eignet sich besonders, wenn zwar eine sehr große Anzahl an Spektralbändern oder sonstigen Eingangskanälen verfügbar ist, aber zur eindeutigen Unterscheidung wenige daraus abgeleitete Layer bereits ausreichen (Basaeed et al. 2012, Zhang 2010) (siehe Beispiel zur Wasserdetektion in Kapitel 4). Da das Ergebnis hier ein Informationslayer statt eines Bilds ist, sind die Qualitätsmaße aus Tabelle 2 nur noch ansatzweise anwendbar.

Die Fusionsmethode der Multirate Filter Banks bietet den Vorteil, dass die Filteroperationen direkt auf den Originalbildern durchgeführt werden können ohne vorherige Umprojektion und Neubabtastung mit den von den Verfahren auf Pixel Level bekannten Fehlerquellen (Ghassemian 2001b, Ghassemian 2016).

Eingesetzt werden die Multirate Filter Banks ähnlich der Brovey- und IHS-Methoden zur Verbesserung der räumlichen Auflösung, erlauben jedoch eine Auswertung der spektralen Signatur, weil im Gegensatz zu Brovey und IHS die fusionierten Bilder keine Verzerrung der spektralen Eigenschaften (siehe Tabelle 2) aufweisen (Ghassemian 2001b). Sämtliche räumlichen Filterverfahren sind aber wegen der zu berechnenden Faltungen extrem rechenaufwendig. Es sei denn, es gelingt, die Faltung im Frequenzraum durchzuführen.

Ein Beispiel dafür ist die Curvelet-Transformation. Es wurde nachgewiesen, dass die Curvelet-Darstellung stückweise lineare Kantenverläufe genauer wiedergibt als alle anderen mathematischen Transformationen (Rao et al. 2014). Eine ungeschickte Fusion führt jedoch zu starken räumlichen Artefakten (Schmitt et al. 2009). Dafür werden die spektralen Eigenschaften (Tabelle 2)

beibehalten (Ghassemian 2016). Dank der effizienten Programmierung der Curvelets zweiter Generation (Rao et al. 2014) ist die Transformation mittlerweile wie bei vielen anderen Methoden der Multiresolution Analysis auch mit Standardcomputern bereits durchführbar (Loncan et al. 2015). Ungeachtet dessen ist der Aufwand deutlich höher als bei Verfahren auf Pixel Level (Ghamisi et al. 2019).

Im Vergleich zur Wavelet-Transformation punkten die Curvelets mit der besseren Adaptation von Kanten jedweder Richtung (Namratha & Raghu 2015). Manche Veröffentlichungen sprechen sogar von Vollständigkeit hinsichtlich Kanten (Dong et al. 2015), weil das komplette Bild ausschließlich in Kanten abgelegt wird. Folglich eignet sich der Curvelet-Ansatz vor allem für strukturierte Bereiche (Choi et al. 2005), selbst unter starkem Rauscheinfluss (Schmitt 2012).

Die Methode kann beispielsweise bei der Fusion von SAR- und multispektralen Bildern sowie von PAN- und multispektralen Bildern angewendet werden. Bei SAR-multispektraler Fusion erwies sich die Curvelet-Methode effizienter bei der Rauschunterdrückung als die Wavelet-Methode (Jiang et al. 2011).

Auch die Markov-Random-Fields werten räumliche Nachbarschaften von Pixeln aus. Im Gegensatz zu den Curvelets wird hier eine fest vorgegebene Umgebung modelliert. Curvelets gehen von quasi unendlichen Wellenfunktionen aus, deren Einfluss jedoch mit Abstand vom zentralen Pixel abnimmt, was sie gegenüber einer Fourier-Transformation wieder stabiler macht. Die Einbeziehung der Nachbarschaften führt in beiden Fällen zu deutlich besseren Fusionsergebnissen (Ghassemian 2016). Die Algorithmen zur Berechnung der Markov-Random-Fields sind rechnerisch sehr zeitaufwendig. Bei der in Kapitel 3.1 beschriebenen Methode stehen die Pixelwerte fest und nur das Kantenmodell wird aktualisiert, um dieses zu verstärken. Auch dieser Algorithmus lässt sich effizient programmieren, sodass eine Nahe-Echtzeit-Anwendung möglich scheint (Wright 1999). Wie es der Name jedoch schon vermuten lässt, steckt in diesem Verfahren auch eine zufällige Komponente, d. h. der Erfolg dieses Verfahrens ist wahrscheinlich, jedoch nicht deterministisch vorhersagbar. Sowohl Curvelets wie auch Markov-Ran-

dom-Fields in der beschriebenen Form verbessern vor allem die eingangs erwähnten räumlichen Aspekte wie Kantenstärke.

Der von Gao et al. (2006) entworfene STARFM-Algorithmus kann verwendet werden, um löchrige Landsat-Zeitreihen mit täglichen MODIS-Aufnahmen zu füllen. Aufgrund der höheren zeitlichen Abtastung von MODIS sind die Chancen auf wolkenfreie Szenen größer als bei Landsat. STARFM stützt sich dabei auf zeitliche Informationen aus reinen homogenen Flächen der Landbedeckung auf der größeren räumlichen Abtastung von MODIS. Der Verknüpfungspunkt beider Sensoren liegt in der gegenseitigen Zuordnung von Kanälen mit gleicher spektraler Empfindlichkeit, z. B. nahes Infrarot mit ähnlicher zentraler Wellenlänge und ähnlicher Bandbreite. Für große homogene und zeitlich stabile Flächen eignet sich diese Fusion perfekt, während feinstrukturierte oder zeitlich variable Flächen ein Problem darstellen (Hilker et al. 2009). Beispielsweise kann der Wechsel zwischen feuchten und

trockenen Gebieten auf sehr engem Raum nicht erfasst werden (Cammalleri et al. 2014). Außer der Empfindlichkeit gegenüber zeitlichen Veränderungen erwähnen Gevaert & García-Haro (2015) noch Verzerrungen wegen der unterschiedlichen Aufnahmegeometrie: etwa 185 km Schwadbreite bei Landsat gegenüber 2.330 km Schwadbreite bei MODIS aus etwa gleicher Flughöhe von gut 700 km.

Auch die hyperkomplexen Basen tauchen unter den Fusionsmethoden auf Feature Level wieder auf. Der Grund hierfür liegt in der möglichen Fusion normierter Kennaugh-Elemente zu sogenannten integralen Kennaugh-Elementen. Hierbei handelt es sich um eine rein radiometrische Fusion, d. h. die Eingangsgrößen erfordern einen normierten Wertebereich wie die typischen Normalized Difference Indizes und eine zumindest ähnliche Aussage, z. B. hohe Werte für Wasser wie im veranschaulichten Beispiel. Dann können Gemeinsamkeiten zusammengefasst und

Unterschiede hervorgehoben werden. Das Ergebnis ist wieder ein normierter Layer, was die Verarbeitung konsistent macht und eine verlustarme Unterabtastung ermöglicht (Schmitt et al. 2020). Somit kann auch ein fusionierter Layer problemlos in 8 bit abgelegt und in jedes Geoinformationssystem eingebunden werden.

5.3 DECISION LEVEL

Auf Entscheidungsebene werden konkrete Informationen fusioniert, Unstimmigkeiten aufgedeckt und damit ein besseres Verständnis für die beobachteten Objekte geschaffen (Pohl & Van Genderen 1998). Bezogen auf das Beispiel aus Kapitel 4 liegen bereits zwei Wassermasken vor. Die Fusion bestätigt das Vorhandensein von Wasser für Bereiche, in denen sich beide Informationsquellen einig sind, und weist Bereiche aus, für die abweichende Informationen vorliegen. Somit ist die Datenmenge bei der Fusion auf Entscheidungsebene im Vergleich zu den anderen Verarbeitungsebe-




Technikwissen punktgenau:

Neueste Forschungsergebnisse und Anwendungen

Die Oldenburger 3D-Tage bieten seit 2002 jährlich eine Plattform für Expertinnen und Experten aus den Bereichen Photogrammetrie, Geodäsie und industrielle Messtechnik. Der aktuelle Tagungsband enthält alle Beiträge der 20. Oldenburger 3D-Tage, u. a. zu den Themen Urban Mobile Mapping, optische Messtechnik für den Unterwassereinsatz oder UAV-RTK.

Preisänderungen und Irrtümer vorbehalten. Sowohl das E-Book als auch das Kombiangebot (Buch + E-Book) sind ausschließlich auf www.vde-verlag.de erhältlich.



2022, X, 422 Seiten
68,- € (Buch/E-Book)
95,20 € (Kombi)

Bestellen Sie jetzt: (030) 34 80 01-222 oder www.vde-verlag.de/buecher/537726



nen minimal (Pandit & Bhiwani 2015). Andererseits wird der Informationsverlust maximal, weil nur noch die Information „Wasser ja/nein“ in den Daten vorhanden ist (Pohl & Van Genderen 1998). Die finale Klassifikation kann entweder auf dem fusionierten Datensatz oder unter Auswertung der einzelnen Eingangslayer erfolgen (Pandit & Bhiwani 2015). Die Fusion auf Decision Level kommt vor allem in großflächigen, voll-automatischen Anwendungen zum Einsatz. Als Beispiele seien die Klassifizierung von Landnutzungsarten, Meereis oder Wolkentypen (Basaeed et al. 2012) oder auch die Water Indication Mask der TanDEM-X-Mission genannt, die den letzten Schritt zu einer eindeutigen Aussage sogar komplett fallen lässt (Wendleder et al. 2012).

Fusionsmethoden auf Decision Level steigern die Zuverlässigkeit, indem die Ergebnisse mehrerer Klassifizierungen mit einbezogen werden. Dies ist auch bei der Similarity im Rahmen der Histogramm-Klassifikation als auch bei der Methode der Fuzzy Decision Rule der Fall. Bei der Histogramm-Klassifikation wird allein aufgrund der Ähnlichkeit von Verteilungen eine Klassenwahrscheinlichkeit berechnet und über alle Eingangsdaten aggregiert. Eine Abwägung verlässlicher und weniger verlässlicher Eingangslayer ist in der veröffentlichten Version noch nicht vorgesehen (Schmitt et al. 2018). Die Methode der Fuzzy Decision Rule unterscheidet bereits zwischen einer globalen und lokalen Zuverlässigkeit, um eine Auswahl zu treffen, welche Information wie verlässlich ist (Fauvel et al. 2006). Dies ist ebenso von Vorteil, wenn verschiedene Informationsquellen gegensätzliche Aussagen liefern (Gamba & Chanussot 2008). Der Algorithmus lässt sich üblicherweise über einen einfachen Entscheidungsbaum abbilden und bedarf keiner aufwendiger Verfahren aus dem Bereich des maschinellen Lernens. Trotzdem ist der Einsatz von fortgeschrittenen Klassifikatoren nicht ausgeschlossen und kann gerade bei zahlreichen Eingangslayern und der Einbeziehung von Metadaten wie beispielsweise dem Aufnahmezeitpunkt zu einer Genauigkeitssteigerung führen (Fauvel et al. 2006).

5.4 HYBRIDE VERFAHREN

Hybride Fusionsmethoden vereinen mehrere Techniken, um deren Vorteile zu kombinieren. So ist das Ziel der IHS-Curvelet-Fusionsmethode, den Vorteil der IHS-Transfor-

mation, welche die spektralen Eigenschaften besser speichern kann, mit dem Vorteil der Curvelet-Methode, welche die räumlichen Informationen besser speichern kann, zu kombinieren (Dong et al. 2015, Vlaizadeh & Ghassemian 2012). Der spektrale und räumliche Informationsgehalt soll also verbessert werden. Ergebnisse zeigen, dass mehr spektrale Merkmale mit weniger räumlicher Verzerrung bewahrt werden.

Laut Vlaizadeh & Ghassemian (2012) erhöht diese Methode den spektralen Informationsgehalt bei gleichzeitiger Minimierung der räumlichen Verzerrungen und übertrifft damit die Ergebnisse von Brovey, IHS und der Curvelet-Transformation einzeln angewandt.

Dies folgern sie aus der quantitativen Analyse basierend auf dem Korrelationskoeffizienten und gemeinsamer Information des multispektralen und des fusionierten Bilds (Vlaizadeh & Ghassemian 2012). Bei Dong et al. (2015), die einen ähnlichen Ansatz verwenden, ist ein vergleichbares Ergebnis nicht zu erkennen. Die Methode ist dazu geeignet, PAN- und multispektrale Bilder zu fusionieren. Von Vorteil bei der Fusion mit dieser hybriden Methode ist, dass keine Neuabtastung der Quellbilder erforderlich ist (Vlaizadeh & Ghassemian 2012). Hybride Verfahren sind meist Spezialanwendungen, die versuchen, die Schwächen der einen Fusionsmethode mit den Stärken einer anderen zu beheben. Zahlreiche weitere Kombinationen sind hier denkbar.

6 FAZIT

Angesichts der immer größer werdenden Bandbreite an Daten, die von verschiedensten Sensoren erfasst werden, und der steten Verbesserungen in den methodischen Ansätzen und Berechnungsinstrumenten, erscheint es sinnvoll, ja fast unumgänglich, die heterogenen Datensätze synergetisch zu fusionieren, um die Effektivität und Effizienz von Fernerkundungsanwendungen weiter zu steigern. Die Datenfusion ist daher ein hochaktuelles Forschungsthema in der bildgebenden Fernerkundung. Die konkreten Ziele der Bildfusion sind die Verbesserung der Lagegenauigkeit, von Bilddatenfehlern, der spektralen Auflösung, der räumlichen Auflösung, der temporalen Auflösung, der radiometrischen Stabilität oder ganz allgemein der Informationstiefe.

Die in diesem Beitrag vorgestellten Fusionsmethoden unterteilen sich in Fusion auf

Pixel, Feature und Decision Level. Zusätzlich wird neben der Komplexität der Methodik auch erstmals die konkrete Anwendung bei der Eingruppierung in einem dreidimensionalen Diagramm berücksichtigt. Die Methoden auf Pixel Level umfassen Arithmetic Combination, Hypercomplex Bases und Component Substitution. Das Feature Level bezieht immer mehrere Messungen mit ein und umfasst die Untergruppen Multiresolution Analysis, Model-based Approaches und noch einmal Hypercomplex Bases. Die Fusion auf Decision Level ist sehr speziell auf einzelne Anwendungen zugeschnitten, weshalb hier keine weiteren Untergruppen mehr ausgewiesen werden können. Daneben gibt es noch hybride Verfahren, die verschiedene Methoden kombinieren.

Bei der kritischen Betrachtung ausgewählter Verfahren kristallisieren sich einige Schlussfolgerungen heraus. Die niedrigste Verarbeitungsebene (Pixel Level) ist, was die Anwendung betrifft, am flexibelsten, aber auch am anfälligsten gegenüber kleineren Fehlereinflüssen wie mangelhafte Koregistrierung. Bei der Fusion geht in der Regel keine Information verloren, sodass man sich auch noch auf keine konkrete Anwendung vorab festlegen muss. Die Fusion auf Feature Level erfordert bereits die zuverlässige Ableitung aussagekräftiger Merkmale für eine bestimmte Anwendung. Daher muss man sich bereits mit den Daten eingehend auseinandergesetzt haben. Dafür sind diese Verfahren etwas robuster gegenüber Fehlereinflüssen. Aufgrund der Beschränkung auf bestimmte Merkmale geht Information verloren, und der Anwender legt sich schon früh auf eine konkrete zu beantwortende Fragestellung fest. Diese Spezialisierung gipfelt in den Verfahren auf Decision Level. Mit sehr viel Expertenwissen werden hier Daten unterschiedlichster Quellen soweit aufbereitet, dass bereits mit nur einem einzelnen Datensatz eine Entscheidung getroffen werden könnte. Die Fusion der unterschiedlichen Datenquellen untermauert lediglich die Zuverlässigkeit der Entscheidung oder stellt diese auch gegebenenfalls infrage. Andererseits bietet genau diese Beschränkung auf einfache, meist binäre Aussagen maximale Flexibilität hinsichtlich Unwägbarkeiten wie der Koregistrierung oder dem zeitlichen Ablauf eines aus dem All beobachteten Prozesses. Kurz zusammengefasst lässt sich sagen: Je greifbarer die finale Anwendung, desto höher kann das

Fusionslevel gewählt werden. Für rein wissenschaftliche Betrachtungen empfiehlt sich weiterhin das Pixel Level aufgrund des Informationserhalts.

Dieser Beitrag liefert einen strukturierten Überblick zu den in der Fernerkundung gebräuchlichen Methoden der Datenfusion zum Zeitpunkt der Veröffentlichung. Auf-

grund der ständigen Weiterentwicklung der Sensoren, Verarbeitungswerkzeuge und Klassifikatoren werden sich auch die Verfahren zur Bilddatenfusion verändern. Derzeit fokussieren Methoden des maschinellen Lernens vor allem auf Pixel Level fusionierte Daten wegen der darin enthaltenen Informationsfülle, klassisch deterministische

Ansätze verwenden das aussagekräftige Feature Level, während Prozessoren die einfach durchzuführende Fusion auf Decision Level bevorzugen. Noch lässt sich schwer abschätzen, wohin die Reise in den vor uns liegenden Jahren gehen wird.

Literatur

- Abdikan, S.; Bildin, G.; Sanli, F. B.; Uslu, E.; Ustuner, M. (2015): Enhancing land use classification with fusing dualpolarized TerraSAR-X and multispectral RapidEye data. In: *Journal of Applied Remote Sensing*, 9. DOI: 10.1117/1.JRS.9.096054.
- Abdikan, S.; Sanli, F. B.; Sunar, F.; Ehlers, M. (2014): A comparative data-fusion analysis of multi-sensor satellite images. In: *International Journal of Digital Earth*, 7 (8), S. 671-687. DOI: 10.1080/17538947.2012.748846.
- Baatz, M.; Schäpe, M. (2000): Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. In: Strobl, J.; Blaschke, T.; Griesebner, G. (Hrsg.): *Angewandte Geographische Informationsverarbeitung XII*. Wichmann, Heidelberg, S. 12-23.
- Bai, X.; Liu, C.; Ren, P.; Zhou, J.; Zhao, H.; Su, Y. (2015): Object classification via feature fusion based marginalized kernels. In: *IEEE Geoscience and Remote Sensing Letters*, 12 (1), S.8-12. DOI: 10.1109/LGRS.2014.2322953.
- Balachander, B.; Dhanasekaran, D. (2016): Comparative Study of Image Fusion Techniques in Spatial and Transform Domain. In: *ARPN Journal of Engineering and Applied Sciences*, 11 (9), S. 5779-5783.
- Basaeed, E.; Bhaskar, H.; Al-Mualla, M. (2012): Beyond Pan-sharpening: Pixel-level Fusion in Remote Sensing Applications. In: *Proceedings of International Conference on Innovations in Information Technology (IIT)*, S. 139-144. DOI: 10.1109/INNOVATIONS.2012.6207718.
- Benediktsson, J. A.; Sveinsson, J. R.; Swain, P. H. (1997): Hybrid consensus theoretic classification. In: *IEEE Transactions on Geoscience and Remote Sensing*, 35 (4), S. 833-843.
- Benediktsson, J. A.; Swain, P. H.; Hu, Q.; Ersoy, O. K. (1990): Neural Network Approaches versus Statistical Methods in Classification of Multi-source Remote Sensing Data. In: *IEEE Transactions on Geoscience and Remote Sensing*, 28 (4), S. 540-552.
- Berger, C.; Voltersen, M.; Schmulius, C.; Hese, S. (2018): Robust mapping of urban structure types using high resolution geospatial data. In: *gis.Science*, 2/2018, S. 47-59.
- Bertram, A.; Wendleder, A.; Schmitt, A.; Huber, M. (2016): Long-term Monitoring of water dynamics in the Sahel region using the Multi-SAR-System. *ISPRS Congress*, 12.-19.07.2016, Prag, Tschechien. DOI: 10.5194/isprsannals-III-7-9-2016.
- Blum, R. S. (2006): On multisensor image fusion performance limits from an estimation theory perspective. In: *Information Fusion*, 7 (3), S. 250-263. DOI: <https://doi.org/10.1016/j.inffus.2004.12.001>.
- Burt, P. J.; Adelson, E. H. (1983): The Laplacian pyramid as a compact image code. In: *IEEE Transactions on Communications*, 31 (4). DOI: <https://doi.org/10.1109/TCOM.1983.1095851>.
- Cammalleri, C.; Anderson, M. C.; Gao, F.; Hain, C. R.; Kustas, W. P. (2014): Mapping daily evapotranspiration at field scales over rainfed and irrigated agricultural areas using remote sensing data fusion. In: *Agricultural Forest Meteorology*, 186, S. 1-11. DOI: 10.1016/j.agrformet.2013.11.001.
- Canga, E. F.; Nikolov, S. G.; Canagarajah, C. N.; Bull, D. R.; Dixon, T. D.; Noyes, J. M.; Troscianko, T. (July 2005): Characterisation of image fusion quality metrics for surveillance applications over bandlimited channels. In: *Proceedings of 7th International Conference on Information Fusion*, Vol. 1. IEEE, S. 8 ff.
- Cao, L.; Liu, J.; Liu, S. (2013): Remote Sensing Image Fusion of Worldview-2 Satellite Data. In: *Applied Mechanics and Materials*, 333-335, S. 1159-1163. DOI: 10.4028/www.scientific.net/AMM.333-335.1159.
- Carper, W.; Lillesand, T.; Kiefer, R. (1990): The use of intensity hue saturation transformations for merging SPOT panchromatic and multispectral image data. In: *Photogrammetric Engineering and Remote Sensing*, 56 (4), S. 459-467.
- Chang, X.; Jiao, L.; Liu, F.; Xin, F. (2010): Multicontourletbased adaptive fusion of infrared and visible remote sensing images. In: *IEEE Geoscience and Remote Sensing Letters*, 7 (3), S. 549-553. DOI: 10.1109/LGRS.2010.2041323.
- Chen, C.; He, X.; Guo, B.; Zhao, X.; Chu, Y. (2020): A pixellevel fusion method for multi-source optical remote sensing image combining the principal component analysis and curvelet transform. In: *Earth Science Informatics*, 13, S. 1005-1013. DOI: <https://doi.org/10.1007/s12145-020-00472-7>.
- Chen, F.; Qin, F.; Peng, G.; Chen, S. (2012): Fusion of Remote Sensing Images Using Improved ICA Mergers Based on Wavelet Decomposition. In: *Procedia Engineering*, 29, S. 2938-2943. DOI: <https://doi.org/10.1016/j.proeng.2012.01.418>.

- Chen, J.; Dowman, I.; Li, S.; Li, Z.; Madden, M.; Mills, J.; Paparoditis, N.; Rottensteiner, F.; Sester, M.; Toth, C.; Trinder, J.; Heipke, C. (2016): Information from imagery: ISPRS scientific vision and research agenda. In: *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, S. 3-21. DOI: <http://dx.doi.org/10.1016/j.isprsjprs.2015.09.008>.
- Cheng, Q.; Liu, H.; Shen, H.; Wu, P.; Zhang, L. (2017): A Spatial and Temporal Nonlocal Filter-Based Data Fusion Method. In: *IEEE Transactions on Geoscience and Remote Sensing*, 55 (8), S. 4476-4488. DOI: 10.1109/TGRS.2017.2692802.
- Cheng, J.; Liu, H.; Liu, T.; Wang, F.; Li, H. (2015): Remote sensing image fusion via wavelet transform and sparse representation. In: *ISPRS Journal of Photogrammetry and Remote Sensing*, 104, S. 158-173. DOI: <https://doi.org/10.1016/j.isprsjprs.2015.02.015>.
- Choi, M. (2006): A New Intensity-Hue-Saturation Fusion Approach to Image Fusion With a Tradeoff Parameter. In: *IEEE Transactions on Geoscience and Remote Sensing*, 44 (6), S. 1672-1682.
- Choi, M.; Kim, R. Y.; Kim, M.-G. (2004): The curvelet transform for image fusion. <https://www.semanticscholar.org/paper/THE-CURVELET-TRANSFORM-FOR-IMAGE-FUSION-Choi-Kim/5a0b5e29c6b9e8f3d44555bfab1570fd99ba5a80> [Zugriff 10/2022].
- Choi, M.; Kim, R. Y.; Nam, M.-R.; Kim, H. O. (2005): Fusion of Multispectral and Panchromatic Satellite Images Using the Curvelet Transform. In: *IEEE Geoscience and Remote Sensing Letters*, 2 (2), S. 136-140.
- Chu, H.; Zhu, W. (2008): Fusion of IKONOS Satellite Imagery Using IHS Transform and Local Variation. In: *IEEE Geoscience and Remote Sensing Letters*, 5 (4), S. 653-657.
- Crist, E. P.; Cicone, R. C. (1984): A physically-based transformation of thematic mapper data – the TM Tasseled cap. In: *IEEE Transactions on Geoscience and Remote Sensing*, 22 (3), S. 256-263.
- Damera-Venkata, N.; Kite, T. D.; Geisler, W. S.; Evans, B. L.; Bovik, A. C. (2000): Image quality assessment based on a degradation model. In: *IEEE Transactions on Image Processing*, 9 (4), S. 636-650.
- Do, M. N.; Vetterli, M. (2005): The contourlet transform: An efficient directional multiresolution image representation. In: *IEEE Transactions on Image Processing*, 14 (12), S. 2091-2106. DOI: 10.1109/TIP.2005.859376.
- Dong, L.; Yang, Q.; Wu, H.; Xiao, H.; Xu, M. (2015): High quality multi-spectral and panchromatic image fusion technologies based on Curvelet transform. In: *Neurocomputing*, 159, S. 268-274. DOI: <https://doi.org/10.1016/j.neucom.2015.01.050>.
- Ehlers, M. (2008): Multi-image Fusion in Remote Sensing: Spatial Enhancement vs. Spectral Characteristics Preservation. In: *Advances in Visual Computing (ISVC 2008)*. Lecture Notes in Computer Science, 5359. Springer, Berlin/Heidelberg. DOI: https://doi.org/10.1007/978-3-540-89646-3_8.
- Ehlers, M.; Klonus, S.; Åstrand, P. J.; Rosso, P. (2010): Multisensor image fusion for pansharpening in remote sensing. In: *International Journal of Image and Data Fusion*, 1 (1), S. 25-45. DOI: 10.1080/19479830903561985.
- Eineder, M.; Fritz, T. et al. (2013): TerraSAR-X Ground Segment, Basic Product Specification Document. Doc. TX-GS-DD-3302. <https://sss.terrasar-x.dlr.de/docs/TX-GS-DD-3302.pdf> [Zugriff 10/2022].
- Elmasry, S. A.; Awad, W. A.; Abd Elhafeez, S. A. (2020): Review of Different Image Fusion Techniques: Comparative Study. In: *Internet of Things – Applications and Future* (Ed. by Ghalwash, A. Z.; El Khameesy, N.; Magdi, D. A.; Joshi, A.). Springer Singapore, S. 41-51. DOI: https://doi.org/10.1007/978-981-15-3075-3_3.
- Fauvel, M.; Chanussot, J.; Benediktsson, J. A. (2006): Decision Fusion for the Classification of Urban Remote Sensing Images. In: *IEEE Transactions on Geoscience and Remote Sensing*, 44 (10), S. 2828-2838. DOI: 10.1109/TGRS.2006.876708.
- Feng, T.; Ma, H.; Cheng, X. (2021): Land-cover classification of high-resolution remote sensing image based on multi-classifier fusion and the improved Dempster-Shafer evidence theory. In: *Journal of Applied Remote Sensing*, 15 (1), S. 1-21. DOI: 10.1117/1.JRS.15.014506.
- Fonseca, L.; Namikawa, L.; Castejon, E.; San-der de Carvalho, L. S.; Duque de Pinho, C. M.; Pagamisse, A. (June 2011): Image Fusion for Remote Sensing Applications. <https://www.in-techopen.com/chapters/15846> [Zugriff 10/2022].
- Fontani, M.; Bianchi, T.; De Rosa, A.; Piva, A.; Barni, M. (2013): A Framework for Decision Fusion in Image Forensics Based on Dempster-Shafer Theory of Evidence. In: *IEEE Transactions on Information Forensics and Security*, 8 (4), S. 593-607. DOI: 10.1109/TIFS.2013.2248727.
- Gamba, P.; Chanussot, J. (2008): Foreword to the Special Issue on Data Fusion. In: *IEEE Transactions on Geoscience and Remote Sensing*, 46 (5), S. 1283-1288.
- Gao, F.; Masek, J.; Schwaller, M.; Hall, F. (2006): On the blending of the Landsat and MODIS surface reflectance: Predicting daily Landsat surface reflectance. In: *Transactions on Geoscience and Remote Sensing*, 44, S. 2207-2218.
- Ghahremani, M.; Ghassemian, H. (2015a): Remote sensing image fusion using ripplet transform and compressed sensing. In: *IEEE Geoscience and Remote Sensing Letters*, 12 (3), S. 502-506. DOI: 10.1109/LGRS.2014.2347955.
- Ghahremani, M.; Ghassemian, H. (2015b): Remote-sensing image fusion based on curvelets and ICA. In: *International Journal of Remote Sensing*, 36 (16), S. 4131-4143. DOI: 10.1080/01431161.2015.1071897.
- Ghahremani, M.; Ghassemian, H. (2016): A Compressed-Sensing-Based Pan-Sharpener Method for Spectral Distortion Reduction. In: *IEEE Transactions on Geoscience and Remote Sensing*, 54 (4), S. 2194-2206. DOI: 10.1109/TGRS.2015.2497309.
- Gevaert, C. M.; García-Haro, F. J. (2015): A comparison of STARFM and an unmixing-based algorithm for Landsat and MODIS data fusion. In: *Remote Sensing of Environment*, 156, S. 34-44.
- Ghamisi, P.; Rasti, B.; Yokoya, N.; Wang, Q.; Hofile, B.; Bruzzone, L.; Bovolo, F.; Chi, M.; Anders, K.; Gloaguen, R.; Atkinson, P. M.; Benediktsson, J. A. (2019): Multisource and Multitemporal Data Fusion in Remote Sensing: A Comprehensive Review of the State of the Art. In: *IEEE Geoscience and Remote Sensing Magazine*, 7 (1), S. 6-39. DOI: 10.1109/MGRS.2018.2890023.

- Gharbia, R.; Azar, A. T.; Baz, A. E.; Hassanien, A. E. (2014): Image Fusion Techniques in Remote Sensing. In: CoRR. <http://arxiv.org/abs/1403.5473>.
- Ghassemian, H. (2001a): A retina based multi-resolution image fusion. In: Proceedings IEEE International Geoscience and Remote Sensing Symposium, 2, S. 709-711.
- Ghassemian, H. (2001b): Multi-sensor image fusion using multirate filter banks. In: Proceedings IEEE International Geoscience and Remote Sensing Symposium, 1, S. 846-849.
- Ghassemian, H. (2016): A review of remote sensing image fusion methods. In: Information Fusion, 32, S. 75-89. DOI: <https://doi.org/10.1016/j.inffus.2016.03.003>.
- Golipour, M.; Ghassemian, H.; Mirzapour, F. (2016): Integrating Hierarchical Segmentation Maps With MRF Prior for Classification of Hyperspectral Images in a Bayesian Framework. In: IEEE Transactions on Geoscience and Remote Sensing, 54 (2), S. 805-816. DOI: 10.1109/TGRS.2015.2466657.
- González-Audicana, M.; Saleta, J. L.; Catalán, R. G.; García, R. (2004): Fusion of multispectral and panchromatic images using improved IHS and PCA mergers based on wavelet decomposition. In: IEEE Transactions on Geoscience and Remote Sensing, 42 (6), S. 1291-1299.
- Gonzalez-Audicana, M.; Saleta, J. L.; Catalan, R. G.; Garcia, R. (2004): Fusion of Multispectral and Panchromatic Images Using Improved IHS and PCA Mergers Based on Wavelet Decomposition. In: IEEE Transactions on Geoscience and Remote Sensing, 42 (6), S. 1291-1299. DOI: 10.1109/TGRS.2004.825593.
- Green, A. A.; Berman, M.; Switzer, P.; Craig, M. D. (1988): A Transformation for Ordering Multispectral Data in Terms of Image Quality with Implications for Noise Removal. In: IEEE Transactions on Geoscience and Remote Sensing, 26 (1), S. 65-74. DOI: 10.1109/36.3001.
- Guo, M.; Zhang, H.; Li, J.; Zhang, L.; Shen, H. (2014): An online coupled dictionary learning approach for remote sensing image fusion. In: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7 (4), S. 1284-1294. DOI: 10.1109/JSTARS.2014.2310781.
- Guo, Q.; Li, A.; Zhang, H. Q.; Feng, Z. K. (2013): Remote Sensing Image Fusion Based on Discrete Fractional Random Transform for Modified HIS. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, S. 19-22.
- Gupta, V.; Mehra, S. (Feb. 2016): Image Fusion Techniques – A Comparative Study. In: International Journal of Engineering Trends and Technology, 32, S. 113-118. DOI: 10.14445/22315381/IJETT-V32P220.
- Ha, W.; Gowda, P. H.; Howell, T. A. (2012): A review of potential image fusion methods for remote sensing-based irrigation management: part II. In: Irrigation Science, 31 (4), S. 851-869.
- Hall, D. L. (1992): Mathematical Techniques in Multisensor Data Fusion. Artech House.
- Henrich, V.; Krauss, G.; Götze, C.; Sandow, C. (2012): IDB – www.indexdatabase.de, Entwicklung einer Datenbank für Fernerkundungsindizes. AK Fernerkundung, Bochum, 4.-5.10.2012.
- Hilker, T.; Wulder, M. A.; Coops, N. C.; Linke, J.; McDermid, G.; Masek, J.; Gao, F.; White, J. C. (2009): A new data fusion model for high spatial-and temporal-resolution mapping of forest disturbance based on Landsat and MODIS. In: Remote Sensing of Environment, 113, S. 1613-1627.
- Hilker, T.; Wulder, M. A.; Coops, N. C.; Sritz, N.; White, J. C.; Gao, F.; Masek, J. G.; Stenhouse, G. (2009): Generation of dense time-series synthetic Landsat data through data blending with MODIS using a spatial and temporal adaptive reflectance fusion model. In: Remote Sensing Environment, 113, S. 1988-1999.
- Huang, B.; Song, H.; Cui, H.; Peng, J.; Xu, Z. (2014): Spatial and spectral image fusion using sparse matrix factorization. In: IEEE Transactions on Geoscience and Remote Sensing, 52 (3), S. 1693-1704. DOI: 10.1109/TGRS.2013.2253612.
- Huber, M.; Hummelbrunner, W.; Raggam, J.; Small, D.; Kosmann, D. (2004): Technical aspects of Envisat-ASAR geocoding capability at DLR. In: Proceedings ENVISAT and ERS Symposium, Salzburg, Austria.
- Jiang, D.; Zhuang, D.; Huang, Y. (2011): Investigation of Image Fusion for Remote Sensing Application. DOI: <http://dx.doi.org/10.5772/56946>. <https://www.intechopen.com/chapters/15838> [Zugriff 10/2022].
- Jimenez, L. O.; Morales-Morell, A. (1999): Classification of hyperdimensional data based on feature and decision fusion approaches using projection pursuit, majority voting, and neural networks. In: IEEE Transactions on Geoscience and Remote Sensing, 37 (3), S. 1360-1366. DOI: 10.1109/36.763300.
- Joshi, M. V.; Bruzzone, L.; Chaudhuri, S. (2006): A Model-Based Approach to Multiresolution Fusion in Remotely Sensed Images. In: IEEE Transactions on Geoscience and Remote Sensing, 44 (9), S. 2549-2562. DOI: 10.1109/TGRS.2006.873340.
- Kahraman, S.; Ertürk, A. (2017): A Comprehensive Review of Pansharpening Algorithms for Gökürk-2 Satellite Images. In: ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, IV-4/W4, S. 263-270. DOI: 10.5194/isprs-annals-IV-4-W4-263-2017.
- Klonus, S. (2008): Comparison of Pansharpening Algorithms for Combining Radar and Multispectral Data. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 37 (6b), S. 189-194.
- Klonus, S.; Ehlers, M. (2009): Performance of evaluation methods in image fusion. In: International Conference on Information Fusion, S. 1409-1416.
- Knauer, K.; Gessner, U.; Fensholt, R.; Kuenzer, C. (2016): An ESTARFM Fusion Framework for the Generation of Large-Scale Time Series in Cloud-Prone and Heterogeneous Landscapes. In: Remote Sensing, 8 (5), S. 425. DOI: <https://doi.org/10.3390/rs8050425>.
- Komal; Dewan, R. (2014): Energy Based Wavelet Image Fusion. In: International Journal for Innovative Research in Science & Technology, 1 (6).
- Laben, C. A.; Brower, B. V. (2000). Process for enhancing the spatial resolution of multispectral imagery using pansharpening. US Patent # 6,011,875. Eastman Kodak Company.
- Li, Q.; Tao, J.; Hu, Q.; Liu, P. (2013): Decision fusion of very high resolution images for urban land-cover mapping based on Bayesian network. In: Journal of Applied Remote Sensing, 7 (1), S. 1-17. DOI: 10.1117/1.JRS.7.073551.

- Li, S.; Yang, B.; Hu, J. (2011): Performance comparison of different multi-resolution transforms for image fusion. In: *Information Fusion*, 12 (2), S. 74-84. DOI: <https://doi.org/10.1016/j.inffus.2010.03.002>.
- Li, Z.; Jing, Z.; Yang, X.; Sun, S. (2005): Color transfer based remote sensing image fusion using non-separable wavelet frame transform. In: *Pattern Recognition Letters*, 26 (13), S. 2006-2014. DOI: <https://doi.org/10.1016/j.patrec.2005.02.010>.
- Loncan, L.; Fabre, S.; Almeida, L. B.; Bioucas-Dias, J. M.; Liao, W.; Briottet, X.; Licciardi, G. A.; Chanussot, J.; Simões, M.; Dobigeon, N.; Tourneret, J.-Y.; Veganzones, M. A.; Wei, Q.; Vivone, G.; Yokoya, N. (2015): Hyperspectral Pansharpening: A Review. In: *IEEE Geoscience and Remote Sensing Magazine*, 3 (3), S. 27-46. DOI: 10.1109/MGRS.2015.2440094.
- Lu, Q.; Huang, X.; Li, J.; Zhang, L. (2016): A Novel MRFBased Multifeature Fusion for Classification of Remote Sensing Images. In: *IEEE Geoscience and Remote Sensing Letters*, 13 (4), S. 515-519. DOI: 10.1109/LGRS.2016.2521418.
- Luo, B.; Khan, M. M.; Bienvenu, T.; Chanussot, J.; Zhang, L. (2013): Decision-based fusion for pansharpening of remote sensing images. In: *IEEE Geoscience and Remote Sensing Letters*, 10 (1), S. 19-23. DOI: 10.1109/LGRS.2012.2189933.
- Luo, Y.; Liu, R.; Zhu, Y. F. (2008): Fusion of remote sensing image base on the PCA+atrous wavelet transform. <https://www.semanticscholar.org/paper/FUSION-OF-REMOTE-SENSING-IMAGE-BASE-ON-THE-PCA-%2B-Luo-Liu/e661175132ba426183fe12148070b4c3e5258d69> [Zugriff 10/2022].
- McFeeters, S. K. (1996): The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. In: *International Journal of Remote Sensing*, 17 (7), S. 1425-1432. DOI: 10.1080/01431169608948714.
- Metwalli, M. R.; Nasr, A. H.; Farag Allah, O. S.; El-Rabaie, S.; Abd El-Samie, F. E. (2010): Satellite image fusion based on principal component analysis and high-pass filtering. In: *Optical Society of America*, 27 (6), S. 1385-1394.
- Mirzapour, F.; Ghassemian, H. (2015): Improving hyperspectral image classification by combining spectral, texture, and shape features. In: *International Journal of Remote Sensing*, 36 (4), S. 1070-1096. DOI: 10.1080/01431161.2015.1007251.
- Namratha, H. N.; Raghu, M. T. (2015): Remote Sensing Satellite Image Fusion Using Fast Curvelet Transforms. In: *International Journal of Science and Research*, 4 (4), S. 1537-1542.
- Nason, G. P.; Silverman, B. W.; Antoniadis, A.; Oppenheim, G. (1995): The Stationary Wavelet Transform and some Statistical Applications. In: *Wavelets and Statistics. Lecture Notes in Statistics*. Springer, New York, NY, S. 281-299. DOI: https://doi.org/10.1007/978-1-4612-2544-7_17.
- Nencini, F.; Garzelli, A.; Baronti, S.; Alparone, L. (2007): Remote sensing image fusion using the curvelet transform. In: *Information Fusion*, 8, S. 143-156. DOI: 10.1016/j.inffus.2006.02.001.
- Nikolakopoulos, K. (2008): Comparison of Nine Fusion Techniques for Very High Resolution Data. In: *Photogrammetric Engineering & Remote Sensing*, 74 (5), S. 647-659.
- Núñez, J.; Otazu, X.; Fors, O.; Prades, A.; Pal'a, V.; Arbiol, R. (1999): Multiresolution-based image fusion with additive wavelet decomposition. In: *IEEE Transactions on Geoscience and Remote Sensing*, 37 (3), S. 1204-1211. DOI: 10.1109/36.763274.
- Pandit, V.; Bhiwani, R. (June 2015): Image Fusion in Remote Sensing Applications: A Review. In: *International Journal of Computer Applications*, 120 (10), S. 22-32. DOI: 10.5120/21263-3846.
- Pogoda B.; Hauser S.; Rothe M.; Bakker F.; Hausen T.; Colsoul B.; Heinicke K.; Pesch R. (2022): GIS-basierte Modellierung von Eignungsflächen für die Wiederansiedlung der europäischen Auster in der AWZ der Nordsee. In: *gis.Science*, 2/2022, S. 47-62.
- Pohl, C. (2013): Challenges of Remote Sensing Image Fusion to Optimize Earth Observation Data Exploitation. In: *European Scientific Journal*, 4, S. 355-365.
- Pohl, C.; Van Genderen, J. L. (1998): Review article Multisensor image fusion in remote sensing: Concepts, methods and applications. In: *International Journal of Remote Sensing*, 19 (5), S. 823-854. DOI: 10.1080/014311698215748.
- Princess, M. R.; Kumar, V. S.; Begum, M. R. (2014): Comprehensive and Comparative Study of Different Image Fusion Techniques. In: *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 3 (9), S. 11800-11806.
- Rao, C. V.; Rao, J. M.; Kumar, A. S.; Jain, D. S.; Dadhwal, V. K. (2014): Satellite image fusion using Fast Discrete Curvelet Transforms. In: *2014 IEEE International Advance Computing Conference (IACC)*, S. 952-957. DOI: 10.1109/IAAdCC.2014.6779451.
- Ranchin, T.; Wald, L. (2000): Fusion of high spatial and spectral resolution images: the ARSIS concept and its implementation. In: *Photogrammetric Engineering and Remote Sensing*, 66 (1), S. 49-61.
- Rashidi, A.; Ghassemian, H. (2003): Extended dempster-shafer theory for multi-system/sensor decision fusion. In: *Commission IV Joint Workshop on Challenges in Geospatial Analysis, Integration and Visualization II*, S. 31-37.
- Rashidi, A.; Ghassemian, H. (2004): A New Approach for Multi-System/Sensor Decision Fusion Based on Joint Measures. In: *International Journal of Information Acquisition*, 1 (2), S. 109-120.
- Rottensteiner, F.; Trinder, J.; Clode, S.; Kubik, K. (2005): Using the Dempster-Shafer method for the fusion of LIDAR data and multi-spectral images for building detection. In: *Information Fusion*, 6 (4), S. 283-300. DOI: <https://doi.org/10.1016/j.inffus.2004.06.004>.
- Saaty, T. L. (1977): A scaling method for priorities in hierarchical structures. In: *Journal of Mathematical Psychology*, 15 (3), S. 234-281. [https://doi.org/10.1016/0022-2496\(77\)90033-5](https://doi.org/10.1016/0022-2496(77)90033-5).
- Sanli, F. B.; Abdikan, S.; Esetlili, M. T.; Sunar, F. (2016): Evaluation of image fusion methods using PALSAR, RADARSAT-1 and SPOT images for land use/ land cover classification. In: *Indian Society of Remote Sensing*, 45 (4), S. 591-601. DOI: 10.1007/s12524-016-0625-y.
- Sanli, F. B.; Abdikan, S.; Esetlili, M. T.; Ustuner, M.; Sunar, F. (2013): Fusion of TerraSAR-X and RapidEye data: a quality analysis. In: *International Journal of Remote Sensing*, 34 (1), S. 1-15. DOI: 10.1080/01431161.2013.771111.

- al Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XL-7/W2, S. 27-30. DOI: 10.5194/isprsarchives-XL-7-W2-27-2013.
- Schmitt, A. (2012): Änderungserkennung in multitemporalen und multipolarisierten Radaraufnahmen. Dissertation, Institut für Photogrammetrie und Fernerkundung (IPF), Karlsruher Institut für Technologie (KIT).
- Schmitt, A. (2016): Multiscale and Multidirectional Multilooking for SAR Image Enhancement. In: IEEE Transactions on Geoscience and Remote Sensing, 54 (9), S. 5117-5134. DOI: 10.1109/TGRS.2016.2555624.
- Schmitt, A.; Sieg, T.; Wurm, M.; Taubenböck, H. (2018): Investigation on the separability of slums by multi-aspect TerraSAR-X dual-co-polarized high resolution spotlight images based on the multi-scale evaluation of local distributions. In: International Journal of Applied Earth Observation and Geoinformation, 64, S. 181-198.
- Schmitt, A.; Wendleder A. (2016): Geometric and Polarimetric Sharpening of SAR Images by Kennaugh- and Schmittlet-based Multi-frequency Data Fusion. In: Proceedings of 11th European Conference on Synthetic Aperture Radar, Hamburg, S. 1086-1089.
- Schmitt, A.; Wendleder, A. (2018): SAR-Sharpening in the Kennaugh Framework applied to the Fusion of multimodal SAR and optical Images. In: ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, IV-1, S. 133-140. DOI: 10.5194/isprsannals-IV-1-133-2018.
- Schmitt, A.; Wendleder, A.; Hinz, S. (2015): The Kennaugh element framework for multi-scale, multi-polarized, multitemporal and multi-frequency SAR image preparation. In: ISPRS Journal of Photogrammetry and Remote Sensing, 102, S. 122-139. DOI: <https://doi.org/10.1016/j.isprsjprs.2015.01.007>.
- Schmitt, A.; Wendleder, A.; Kleynmans, R.; Hell, M.; Roth, A.; Hinz, S. (2020): Multi-Source and Multi-Temporal Image Fusion on Hypercomplex Bases. In: Remote Sensing, 12 (6). DOI: 10.3390/rs12060943.
- Schmitt, A.; Wessel, B.; Roth, A. (2009): Curvelet Approach for SAR Image Denoising, Structure Enhancement, and Change Detection. In: Proceedings City Models, Roads and Traffic (CMRT), 03.-04.09.2009, Paris, S. 151-156.
- Schmitt, A.; Wessel, B.; Roth, A. (2014): An Innovative Curvelet-only-Based Approach for Automated Change Detection in Multi-Temporal SAR Imagery. In: Remote Sensing, 6, S. 2435-2462.
- Schmitt, M.; Zhu, Xiao X. (2016): Data Fusion and Remote Sensing: An ever-growing relationship. In: IEEE Geoscience and Remote Sensing Magazine, 4 (4), S. 6-23. DOI: 10.1109/MGRS.2016.2561021.
- Schollerer, L.; Schmitt, A.; Wendleder, A.; Rogginger, S. (2022): Schritthaltende Baufallerkundung aus dem All mit frei verfügbaren Satelliten-aufnahmen. In: Zeitschrift für Geodäsie, Geoinformation und Landmanagement (zfv), 3/2022, S. 168-180. DOI: 10.12902/zfv-0391-2022.
- Shah, V. P.; Younan, N. H.; King, R. L. (2008): An Efficient Pan-Sharpening Method via a Combined Adaptive PCA Approach and Contourlets. In: IEEE Transactions on Geoscience and Remote Sensing, 46 (5), S. 1323-1335. DOI: 10.1109/TGRS.2008.916211.
- Shahdoosti, H. R.; Ghassemian, H. (2015): Fusion of MS and PAN images preserving spectral quality. In: IEEE Geoscience and Remote Sensing Letters, 12 (3), S. 611-615. DOI: 10.1109/LGRS.2014.2353135.
- Shahdoosti, H. R.; Ghassemian, H. (2016): Combining the spectral PCA and spatial PCA fusion methods by an optimal filter. In: Information Fusion, 27, S. 150-160. DOI: <https://doi.org/10.1016/j.inffus.2015.06.006>.
- Shensa, M. J. (1992): The discrete wavelet transform: Wedding the á trous and Mallat algorithm. In: IEEE Transactions on Signal Processing, 40 (10), S. 2464-2482.
- Shi, W.; Zhu, C.; Tian, Y.; Nichol, J. (2005): Wavelet-based image fusion and quality assessment. In: International Journal of Applied Earth Observation and Geoinformation, 6 (3-4), S. 241-251. DOI: 10.1016/j.jag.2004.10.010.
- Simone, G.; Farina, A.; Morabito, F. C.; Serpico, S. B.; Bruzzone, L. (2002): Image fusion techniques for remote sensing applications. In: Information Fusion, 3, S. 3-15.
- Song, H.; Huang, B.; Liu, Q.; Zhang, K. (2015): Improving the Spatial Resolution of Landsat TM/ETM+ Through Fusion with SPOT5 Images via Learning-Based Super-Resolution. In: IEEE Transactions on Geoscience and Remote Sensing, 53 (3), S. 1195-1204. DOI: 10.1109/TGRS.2014.2335818.
- Sun, J.; Zhu, H.; Xu, Z.; Han, C. (2013): Poisson image fusion based on Markov random field fusion model. In: Information Fusion, 14 (3), S. 241-254. DOI: <https://doi.org/10.1016/j.inffus.2012.07.003>.
- Sziranyi, T.; Shadaydeh, M. (2014): Segmentation of Remote Sensing Images Using Similarity-Measure-Based Fusion-MRF Model. In: IEEE Geoscience and Remote Sensing Letters, 11 (9), S. 1544-1548. DOI: 10.1109/LGRS.2014.2300873.
- Tabib Mahmoudi, F.; Samadzadegan, F.; Reintartz, P. (2015): Object recognition based on the context aware decisionlevel fusion in multiviews imagery. In: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 8 (1), S. 12-22. DOI: 10.1109/JSTARS.2014.2362103.
- Tu, T.-M.; Huang, P. S.; Hung, C.-L.; Chang, C.-P. (2004): A fast intensity-hue-saturation fusion technique with spectral adjustment for IKONOS imagery. In: IEEE Geoscience and Remote Sensing Letters, 1 (4), S. 309-312.
- Tu, T.-M.; Su, S.-C.; Shyu, H.-C.; Huang, P. S. (2001): A new look at IHS-like image fusion methods. In: Information Fusion, 2 (3), S. 177-186.
- Tucker, C. (1979): Red and photographic infrared linear combinations for monitoring vegetation. In: Remote Sensing of Environment, 8 (2), S. 127-150.
- Ullmann, T.; Schmitt, A.; Roth, A.; Duffe, J.; Dech, S.; Hubberten, H.-W.; Baumhauer, R. (2014): Land Cover Characterization and Classification of Arctic Tundra Environments by Means of Polarized Synthetic Aperture X- and C-Band Radar (PolSAR) and Landsat 8 Multispectral Imagery – Richards Island, Canada. In: Remote Sensing, 6/2014, S. 8565-8593. DOI: <https://doi.org/10.3390/rs6098565>.
- Van Genderen, J. L.; Pohl, C. (1994): Image fusion: issues, techniques and applications. In: Intelligent Image Fusion, Proceedings EARSel Workshop, S. 18-26.

- Vlaizadeh, S. A.; Ghassemian, H. (2012): Remote Sensing Image Fusion Using Combining IHS and Curvelet Transform. In: International Symposium on Telecommunications, S. 1184-1189.
- Wald, L. (1999): Some terms of reference in data fusion. In: IEEE Transactions on Geoscience and Remote Sensing, 37 (3), S. 1190-1193. DOI: 10.1109/36.763269.
- Wang, B.; Wang, C. (May 2014): The Research of Remote Sensing Image Fusion Technology. In: Applied Science, Materials Science and Information Technologies in Industry, 513. Trans Tech Publications Ltd, S. 3237-3240. DOI: 10.4028/www.scientific.net/AMM.513-517.3237.
- Wang, H.-H.; Peng, J.-X.; Wu, W. (2003): A Fusion Algorithm of Remote Sensing Image Based on Discrete Wavelet Packet. In: Proceedings of the Second International Conference on Machine Learning and Cybernetics, S. 2557-2562.
- Wei, Q.; Bioucas-Dias, J.; Dobigeon, N.; Tourneret, J.-Y. (2015): Hyperspectral and Multispectral Image Fusion Based on a Sparse Representation. In: IEEE Transactions on Geoscience and Remote Sensing, 53 (7), S. 3658-3668. DOI: 10.1109/TGRS.2014.2381272.
- Wei, Q.; Dobigeon, N.; Tourneret, J.-Y. (2015a): Bayesian Fusion of Multi-Band Images. In: IEEE Journal of Selected Topics in Signal Processing, 9 (6), S. 1117-1127. DOI: 10.1109/JSTSP.2015.2407855.
- Wei, Q.; Dobigeon, N.; Tourneret, J.-Y. (2015b): Fast Fusion of Multi-Band Images Based on Solving a Sylvester Equation. In: IEEE Transactions on Image Processing, 24 (11), S. 4109-4121. DOI: 10.1109/TIP.2015.2458572.
- Wenbo, W.; Jing, Y.; Tingjun, K. (2008): Study of Remote Sensing Image Fusion and its Application in Image Classification. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 37 (B7), S. 1141-1146.
- Wendleder, A.; Schmitt, A.; Erbertseder, T.; d'Angelo, P.; Mayer, C.; Braun, M. (2021): Seasonal evolution of supraglacial lakes on Baltoro Glacier from 2016 to 2020. In: Frontiers in Earth Science, 9, S. 1-16. DOI: 10.3389/feart.2021.725394.
- Wendleder, A.; Wessel, B.; Roth, A.; Breunig, M.; Martin, K.; Wagenbrenner, S. (2012): TanDEM-X Water Indication Mask: Generation and First Evaluation Results. In: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. IEEE, S. 1-9. DOI: 10.1109/JSTARS.2012.2210999.
- Wright, W. A. (1999): Fast image fusion with a Markov random field. In: Seventh International Conference on Image Processing and its Applications, 1999 (Conf. Publ. No. 465), 2, S. 557-561. DOI: 10.1049/cp:19990384.
- Wu, Z.; Huang, Y.; Zhang, K. (2018): Remote Sensing Image Fusion Method Based on PCA and Curvelet Transform. In: Journal of the Indian Society of Remote Sensing, 46 (5), S. 687-695.
- Xu, J.; Yang, L.; Wu, D. (2010): Ripple: A new transform for image processing. In: Journal of Visual Communication and Image Representation, 21 (7), S. 627-639. DOI: https://doi.org/10.1016/j.jvcir.2010.04.002.
- Xu, M.; Chen, H.; Varshney, P. K. (2011): An image fusion approach based on markov random fields. In: IEEE Transactions on Geoscience and Remote Sensing, 49 (12), Part 2, S. 5116-5127. DOI: 10.1109/TGRS.2011.2158607.
- Yuan, Y.; Chai, H. (2020): Knowledge fusion method based on fuzzy set theory. In: Journal of Intelligent & Fuzzy Systems, 38 (4), S. 3971-3979. DOI: 10.3233/JIFS-179622.
- Yuhendra; Alimuddin, I.; Sumantyo, J. T. S.; Kuze, H. (2012): Assessment of pan-sharpening methods applied to image fusion of remotely sensed multi-band data. In: International Journal of Applied Earth Observation and Geoinformation, 18, S. 165-175. DOI: https://doi.org/10.1016/j.jag.2012.01.013.
- Zhang, J. (2010): Multi-source remote sensing data fusion: status and trends. In: International Journal of Image and Data Fusion, 1 (1), S. 5-24. DOI: 10.1080/19479830903561035.
- Zhao, S.; Chen, X.; Wang, S.; Li, J.; Yang, W. (2003): A New Method of Remote Sensing Image Decision-Level Fusion Based on Support Vector Machine. In: Proceedings of International Conference on Recent Advances in Space Technologies, 2003 (RAST '03), S. 91-96. DOI: 10.1109/RAST.2003.1303889.
- Zheng, S.; Shi, W.-Z.; Liu, J.; Tian, J. (2008): Remote sensing image fusion using multiscale mapped LS-SVM. In: IEEE Transactions on Geoscience and Remote Sensing, 46 (5), S. 1313-1322. DOI: 10.1109/TGRS.2007.912737.
- Zhou, X.; Liu, J.; Liu, S.; Cao, L.; Zhou, Q.; Huang, H. (2014): A GHS-based spectral preservation fusion method for remote sensing images using edge restored spectral modulation. In: ISPRS Journal of Photogrammetry and Remote Sensing, 88, S. 16-27.
- Zhu, H.; Basir, O.; Karray, F. (2002): Data fusion for pattern classification via the Dempster-Shafer evidence theory. In: IEEE International Conference on Systems, Man and Cybernetics, 7. IEEE, S. 2-3.
- Zhu, X.; Chen, F.; Gao, F.; Chen, X.; Masek, J. G. (2010): An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions. In: Remote Sensing of Environment, 114 (11), S. 2610-2623. DOI: https://doi.org/10.1016/j.rse.2010.05.032.

Fusionsmethode	Literatur
Pixel Level	
<i>Arithmetic Combination</i>	
Adding	Pohl & Van Genderen 1998
Difference	Pohl & Van Genderen 1998
Multiplication	Klonus & Ehlers 2009, Nikolakopoulos 2008, Pandit & Bhiwani 2015, Pohl & Van Genderen 1998
Brovey Transform (BT)	Abdikan et al. 2014, Fonseca et al. 2011, Gharbia et al. 2014, Ghassemian 2016, Ha et al. 2012, Jiang et al. 2011, Kahraman & Ertürk 2017, Klonus & Ehlers 2009, Komal & Dewan 2014, Nikolakopoulos 2008, Pandit & Bhiwani 2015, Pohl 2013, Pohl & Van Genderen 1998, Vlaizadeh & Ghassemian 2012
Minimum/Maximum	Balachander & Dhanasekaran 2016, Gupta & Mehra 2016, Pandit & Bhiwani 2015, Princess et al. 2014
Average	Balachander & Dhanasekaran 2016, Elmasry et al. 2020, Gupta & Mehra 2016, Pandit & Bhiwani 2015, Princess et al. 2014
Ratio Images	Pohl & Van Genderen 1998
Synthetic Variable Ratio (SVR)	Jiang et al. 2011, Zhang 2010
Ratio Enhancement (RE)	Jiang et al. 2011
University of New Brunswick (UNB)	Kahraman & Ertürk 2017, Klonus 2008, Klonus & Ehlers 2009, Pohl 2013
Hypercomplex Bases	Schmitt et al. 2020
<i>Component Substitution (CS)</i>	
Intensity-Hue-Saturation (IHS)	Abdikan et al. 2014, Balachander & Dhanasekaran 2016, Carper et al. 1990, Chu & Zhu 2008, Dong et al. 2015, Fonseca et al. 2011, Gamba & Chanussot 2008, Gharbia et al. 2014, Ghassemian 2016, Guo et al. 2013, Gupta & Mehra 2016, Ha et al. 2012, Jiang et al. 2011, Kahraman & Ertürk 2017, Klonus 2008, Klonus & Ehlers 2009, Komal & Dewan 2014, Nikolakopoulos 2008, Pandit & Bhiwani 2015, Pohl 2013, Pohl & Van Genderen 1998, Sanli et al. 2016, Vlaizadeh & Ghassemian 2012, Wenbo et al. 2008, Zhang 2010
Fast IHS	Choi 2006, González-Audícana et al. 2004, Tu et al. 2004
Generalized IHS	González-Audícana et al. 2004, Tu et al. 2001, Zhou et al. 2014
Modified IHS Transform (M-IHS)	Nicolakopoulos 2008, Yuhendra et al. 2012
Principal Component Analysis (PCA)	Balachander & Dhanasekaran 2016, Chen et al. 2020, Elmasry et al. 2020, Fonseca et al. 2011, Gharbia et al. 2014, Ghassemian 2016, González-Audícana et al. 2004, Green et al. 1988, Gupta & Mehra 2016, Ha et al. 2012, Jiang et al. 2011, Kahraman & Ertürk 2017, Klonus & Ehlers 2009, Komal & Dewan 2014, Loncan et al. 2015, Metwalli et al. 2010, Nikolakopoulos 2008, Pohl 2013, Pohl & Van Genderen 1998, Princess et al. 2014, Shahdoosti & Ghassemian 2016, Simone et al. 2002, Wenbo et al. 2008
Feature Level	
<i>Model-based</i>	
Markov Random Field Model (MRF)	Wright 1999
Non-Local Means Filters	Ulmann et al. 2014
Markov-Zufallsfeld-Prioritäten im Bayes'schen Rahmen	Golipour et al. 2016
Softmax Regression-based Feature Fusion	Bai et al. 2015, Ghassemian 2016
STARFM	Gao et al. 2006
STAARCH	Hilker et al. 2009
ESTARFM	Zhu et al. 2010

STNLFFM	Cheng et al. 2017
Multiresolution Analysis (MRA)	
Wavelet Transform	Balachander & Dhanasekaran 2016, Fonseca et al. 2011, Gharbia et al. 2014, Ha et al. 2012, Jiang et al. 2011, Kahraman & Ertürk 2017, Klonus & Ehlers 2009, Komal & Dewan 2014, Nikolakopoulos 2008, Pandit & Bhiwani 2015, Pohl & Van Genderen 1998, Simone et al. 2002, Vlaizadeh & Ghassemian 2012, Wang & Wang 2014
Discrete "Wavelet Packet"	Ghassemian 2016, Wang et al. 2003
Discrete Wavelet Transform (DWT)	Balachander & Dhanasekaran 2016, Elmasry et al. 2020, Gupta & Mehra 2016, Komal & Dewan 2014, Metwalli et al. 2010, Sanli et al. 2016, Simone et al. 2002
Additive Wavelet Luminance (AWL)	Kahraman & Ertürk 2017, Klonus 2008, Klonus & Ehlers 2009
Additive Wavelet Luminance Proportional (AWLP)	Kahraman & Ertürk 2017, Klonus 2008, Klonus & Ehlers 2009
À Trous Wavelet	Ha et al. 2012, Kahraman & Ertürk 2017, Shensa 1992
Stationary Wavelet Transform (SWT)	Balachander & Dhanasekaran 2016, Elmasry et al. 2020, Li et al. 2011, Metwalli et al. 2010, Nason et al. 1995
Dual-tree Complex Wavelet (DTCWT)	Li et al. 2011, Princess et al. 2014
Bandelet Transform	Ha et al. 2012
Curvelet Transform/Fast Discrete Curvelet Transform (FDCT)	Chen et al. 2020, Choi et al. 2004, Choi et al. 2005, Dong et al. 2015, Ghahremani & Ghassemian 2015b, Ha et al. 2012, Jiang et al. 2011, Li et al. 2011, Namratha & Raghu 2015, Nencini et al. 2007, Pandit & Bhiwani 2015, Princess et al. 2014, Rao et al. 2014, Schmitt 2011, Vlaizadeh & Ghassemian 2012, Wu et al. 2018
Contourlet Transform	Do & Vetterli 2005, Ghassemian 2016, Ha et al. 2012, Jiang et al. 2011, Li et al. 2011, Pandit & Bhiwani 2015, Shah et al. 2008
Multicontourlet	Chang et al. 2010
Ripplet	Ghahremani & Ghassemian 2015a, Xu et al. 2010
Gaussian Pyramid	Cao et al. 2013, Ha et al. 2012, Kahraman & Ertürk 2017, Loncan et al. 2015, Pandit & Bhiwani 2015
Laplacian Pyramid	Burt & Adelson 1983, Elmasry et al. 2020, Gupta & Mehra 2016, Ha et al. 2012, Kahraman & Ertürk 2017, Komal & Dewan 2014, Loncan et al. 2015, Pandit & Bhiwani 2015, Simone et al. 2002
Enhanced Laplacian Pyramid	Kahraman & Ertürk 2017
Generalized Laplacian Pyramid	Kahraman & Ertürk 2017
Multiresolution Fusion Based on Superresolution	Joshi et al. 2006
High-Pass Filter (HPF)	Abdikan et al. 2015, Ha et al. 2012, Kahraman & Ertürk 2017, Klonus & Ehlers 2009, Komal & Dewan 2014, Metwalli et al. 2010, Pohl & Van Genderen 1998, Sanli et al. 2016, Sanli et al. 2013, Wenbo et al. 2008, Yuhendra et al. 2012, Zhang 2010
Filter-based	Shahdoosti & Ghassemian 2015
Least-squares Support Vector Machine (LS-SVM)	Ghassemian 2016, Zheng et al. 2008
Bi-dimensional Empirical Mode Decomposition	Zhang 2010
Smoothing Filter-based Intensity Modulation (SFMI)	Ha et al. 2012, Kahraman & Ertürk 2017, Loncan et al. 2015
Combination of Texture, Shape and Spectral Information	Mirzapour & Ghassemian 2015
MRF-based Multifeature Fusion	Lu et al. 2016
Multirate Filter Banks	Ghassemian 2001b, Ghassemian 2016
Retina-based Multi-resolution	Ghassemian 2001a, Ghassemian 2016

Learning-based Superresolution Fusion	Song et al. 2015
Huang-Hilbert Transform	Gamba & Chanussot 2008
Gram-Schmidt (GS)	Laben & Brower 2000
Decision Level	
Hybrid Methods Based on Consensus	Benediktsson et al. 1997
Voting	Jimenez & Morales-Morell 1999
Rank-based	Rashidi & Ghassemian 2003
Context Aware	Tabib Mahmoudi et al. 2015
Bayesian Network	Li et al. 2013
Dempster-Shafer	Feng et al. 2021, Fontani et al. 2013, Jiang et al. 2011, Rottensteiner et al. 2005, Zhu et al. 2002
Joint Measures Method	Ghassemian 2016, Rashidi & Ghassemian 2004
Post Classification Data Fusion	Schollerer et al. 2022
Fuzzy Decision Rule	Fauvel et al. 2006, Gamba & Chanussot 2008, Ghassemian 2016, Schmitt & Zhu 2016, Yuan & Chai 2020
Histogramm-Klassifikation	Schmitt et al. 2018
Combination of Linear Regression and the Hausdorff Distance	Wendleder et al. 2021
AHP	Saaty 1977, Pogoda et al. 2022
Adaptive Decision Fusion Based on the Local Scale of the Structure	Luo et al. 2013
Statistical Methods	Benediktsson et al. 1990
Multiresolution Segmentation Region Growing Algorithm	Baatz & Schäpe 2000, Berger et al. 2018
Neuronal Network	Benediktsson et al. 1990, Jimenez & Morales-Morell 1999
Hybrid	
À Trous Wavelet and PCA	Luo et al. 2008
Wavelet with HIS or PCA	Gonzalez-Audicana et al. 2004, Nüñez et al. 1999
Non-separable Wavelet Frame Transform (NWFT)	Ghassemian 2016, Li et al. 2005
Wavelet Transform and Sparse Representation	Cheng et al. 2015, Ghassemian 2016
Discrete Multiwavelet Transform and HIS Method	Wang & Wang 2014
Ripplet Transform and the Compressed Sensing	Ghahremani & Ghassemian 2015a
Independent Component Analysis (ICA) and Curvelet	Ghahremani & Ghassemian 2015b
ICA and Wavelet Decomposition	Chen et al. 2012
Curvelet and IHS	Dong et al. 2015, Vlaizadeh & Ghassemian 2012
Curvelet and PCA	Chen et al. 2020, Wu et al. 2018
PCA and HPF	Metwalli et al. 2010
Ehlers Transform	Abdikan et al. 2015, Abdikan et al. 2014, Klonus 2008, Klonus & Ehlers 2009, Pohl 2013, Sanli et al. 2016, Sanli et al. 2013, Yuhendra et al. 2012

Table A1: Literaturtabelle zu den Fusionsmethoden