

Erste Erfahrungen mit der Nutzung von Sentinel-2 Daten zur multispektralen und multitemporalen Analyse mit verschiedenen Klassifizierungsverfahren

MARTIN WEINMANN¹ & UWE WEIDNER¹

Zusammenfassung: In diesem Beitrag steht die multitemporale Analyse von Sentinel-2 Daten zur Klassifizierung bezüglich diverser Landbedeckungs- und Landnutzungsklassen im Vordergrund. Basierend auf den Reflektanzwerten der einzelnen spektralen Kanäle wird mit verschiedenen Klassifizierungsverfahren eine semantische Interpretation eines betrachteten Gebiets durchgeführt, wobei Sentinel-2 Daten für verschiedene Zeitpunkte separat und in Kombination betrachtet werden. Anhand von definierten Kontrollgebieten erfolgt jeweils eine Bewertung der erzielten Ergebnisse. Dabei wird deutlich, dass durch die multitemporale Analyse von Sentinel-2 Daten eine signifikante Verbesserung der entsprechenden Klassifizierungsergebnisse erreicht werden kann.

1 Einleitung

Die Sentinel-2 Satelliten werden zur systematischen Erfassung von Beobachtungen über Land und Küstengebieten genutzt (SPOTO et al. 2012; KUKAWSKA et al. 2017). Sie bieten im Vergleich zu vorherigen Erdbeobachtungssystemen sowohl hinsichtlich der Auflösung als auch bezüglich der Aufnahmezeit eine verbesserte Verfügbarkeit flächendeckender Multispektraldaten. Dadurch kann eine Szenenanalyse anhand von Satellitendaten deutlich begünstigt werden. Während die multispektrale Analyse einer Szene mit verbesserter geometrischer und spektraler Auflösung beispielsweise zur genaueren Kartierung und besseren Unterscheidung von diversen Landbedeckungs- und Landnutzungsklassen genutzt werden kann, erlaubt die multitemporale Analyse eine Beschreibung von dynamischen Prozessen. Jedoch kann die multitemporale Analyse auch zur Verbesserung der mit der multispektralen Analyse erzielten Ergebnisse beitragen. Dies ist insbesondere dadurch bedingt, dass das spektrale Verhalten verschiedener Objekte von zahlreichen Einflussfaktoren abhängt (z.B. vom Wettergeschehen, von der Jahreszeit oder von der Oberflächenbeschaffenheit von Objekten) und durch die Datenaufzeichnung über mehrere Zeitpunkte hinweg zuverlässigere Aussagen über die jeweilige Klassenzugehörigkeit möglich werden.

Im Rahmen dieses Beitrags wird die multispektrale und multitemporale Analyse von Sentinel-2 Daten genauer beleuchtet. Dabei werden Sentinel-2 Daten eines gemischt urban-ländlich geprägten Gebietes, welche für verschiedene Zeitpunkte vorliegen, sowohl pro Zeitpunkt als auch für die Kombination bezüglich verschiedener Zeitpunkte analysiert. Für jeden dieser Fälle werden anhand von definierten Trainingsgebieten zunächst die internen Parameter von verschiedenen Klassifizierungsverfahren ermittelt, wobei letztere durch einen Nearest-Neighbor-Klassifikator, einen naiven Bayes-Klassifikator, eine lineare Diskriminanz-Analyse, einen Random Forest und zwei Varianten der Support Vector Machine gegeben sind. Anschließend erfolgt pro Klassifizie-

¹ Karlsruher Institut für Technologie, Institut für Photogrammetrie und Fernerkundung, Englerstraße 7, D-76131 Karlsruhe, E-Mail: [Martin.Weinmann, Uwe.Weidner]@kit.edu

rungsverfahren eine Klassifizierung für die gesamte Szene, z.B. wie in Abb. 1 angedeutet, sowie eine Bewertung der erzielten Ergebnisse anhand von definierten Kontrollgebieten. Die erzielten Ergebnisse zeigen das Potential einer multitemporalen Analyse deutlich auf, wobei für die betrachtete Szene eine signifikante Steigerung der Gesamtgenauigkeit mit bis zu >10% erreicht wurde.

Nach einem kurzen Abriss des aktuellen Stands der Forschung (Kapitel 2) folgt eine detaillierte Erläuterung der verwendeten Methodik (Kapitel 3). Daraufhin werden die durchgeführten Experimente beschrieben (Kapitel 4) und die erzielten Ergebnisse diskutiert (Kapitel 5). Abschließend folgen eine Zusammenfassung und ein Ausblick (Kapitel 6).

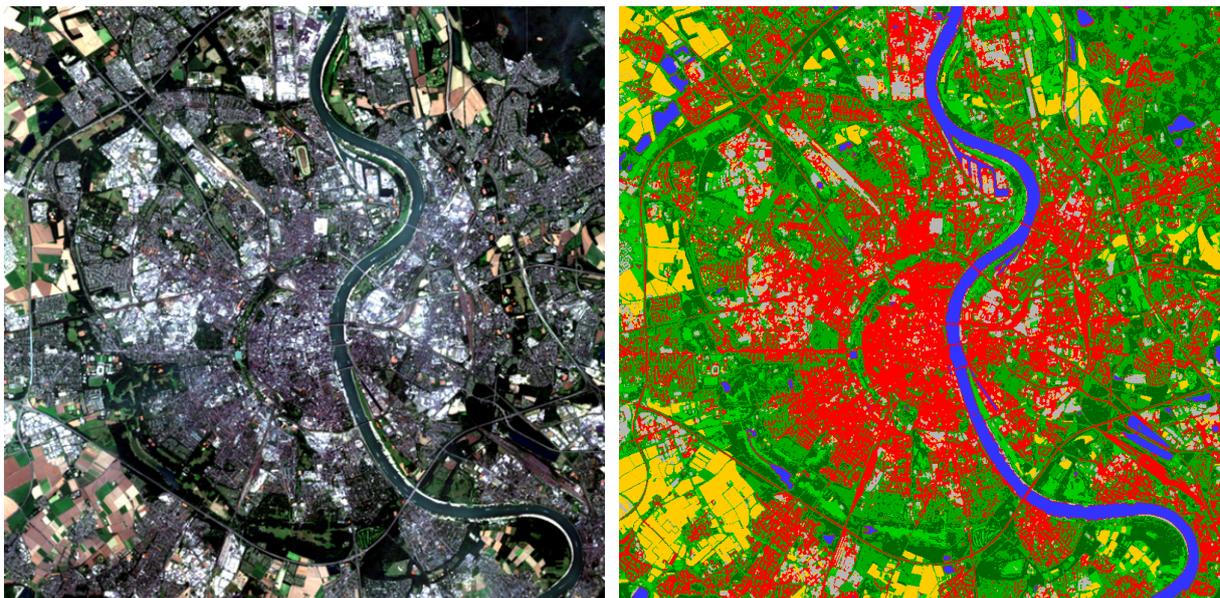


Abb. 1: Eine betrachtete Szene (links) und das entsprechende Klassifizierungsergebnis (rechts), wobei die Klassen durch *Siedlung* (rot), *Industrie* (grau), *Feld* (gelb), *Wald* (dunkelgrün), *Garten* (grün), *Wiese* (hellgrün) und *Wasser* (blau) gegeben sind

2 Stand der Forschung

Unter der Annahme von gegebenen repräsentativen Trainingsdaten kann die Klassifizierung von Sentinel-2 Daten bezüglich diverser Landbedeckungs- und Landnutzungsklassen in Analogie zur Klassifizierung von anderen Typen von Satellitenbildern durchgeführt werden. Beispielsweise können bei Sentinel-2 Daten, welche für einen Zeitpunkt erfasst wurden und typischerweise als Bildstapel vorliegen, die Reflektanzwerte der einzelnen Spektralkanäle pro Pixel als Einträge von Merkmalsvektoren dienen. Demgegenüber können auch spektrale Indizes wie z.B. der Normalized Difference Vegetation Index (NDVI) oder der Normalized Difference Water Index (NDWI) für die Definition von Merkmalsvektoren genutzt werden sowie eine bestimmte Auswahl von relevanten Kanälen (ZHANG et al. 2017). Die definierten Merkmalsvektoren können wiederum als Grundlage, d.h. als Eingangswerte, für diverse Klassifizierungsverfahren genutzt werden, wobei Standardklassifizierungsverfahren durch eine Support Vector Machine (CORTES

& VAPNIK 1995) oder einen Random Forest (BREIMAN 2001) gegeben und mittlerweile in vielen Softwarepaketen vorhanden sind.

Um bei der Analyse von Satellitenbildern zusätzlich den Einfluss verschiedener Jahreszeiten zu berücksichtigen, die sich insbesondere auf die Erscheinung von Vegetation in den entsprechenden Daten auswirken, wird in der Regel eine multitemporale Analyse durchgeführt. Hierbei werden für ein betrachtetes Gebiet die korrespondierenden Daten für verschiedene Zeitpunkte analysiert, wobei beispielsweise für jedes Pixel die Reflektanzwerte der einzelnen Spektralkanäle pro Zeitpunkt zur Definition von Merkmalsvektoren genutzt werden. Die resultierenden Merkmalsvektoren können dann wiederum mit Standardklassifizierungsverfahren wie z.B. einer Support Vector Machine oder einem Random Forest den entsprechend definierten Klassen zugeordnet werden (GÓMEZ et al. 2016). Solche Klassifizierungsstrategien lassen sich auch direkt auf die multitemporale Analyse von Sentinel-2 Daten übertragen, was beispielsweise zur Schätzung der Verteilung von Baumarten in bewaldeten Ökosystemen genutzt wurde (KARASIAK et al. 2017). Desweiteren kann mittels einer multitemporalen Analyse von Sentinel-2 Daten eine sehr genaue Analyse von landwirtschaftlichen Nutzflächen betrieben werden (BRUZZONE et al. 2017). Hierbei wurde eine Support Vector Machine zur Klassifizierung genutzt und, um zusätzlich noch limitierende Faktoren durch Störungen in den Daten (etwa durch Wolkenbedeckung) und die gegebene temporale Auflösung der vorliegenden Sentinel-2 Daten zu berücksichtigen, eine Rekonstruktion der Zeitreihe durchgeführt. Letzteres gelang durch den Einsatz eines nicht-parametrischen Regressions-Modells in Form eines Multi-Layer Perceptrons, mit welchem eine Sentinel-2 Zeitreihe in Tagesschritten rekonstruiert wurde. Neben der spektralen und temporalen Information in den Daten wurden im Rahmen einer anderen Studie (SOLANO-CORREA et al. 2017) auch räumliche Informationen in den Satellitenbildern mittels Zusammenhangskomponenten einbezogen, was die Separierung von einzelnen Feldern und deren Analyse mit einer hohen zeitlichen Auflösung ermöglicht.

3 Methodik

Die verwendete Methodik zur Analyse von multitemporalen Sentinel-2 Daten basiert auf der Verwendung von Reflektanzwerten, die zu Spektralkanälen korrespondieren und zur Definition von Merkmalsvektoren genutzt werden (Kapitel 3.1). Die Merkmalsvektoren dienen wiederum als Eingangsgrößen für ein Klassifizierungsverfahren, welches die jeweiligen Klassenzugehörigkeiten ermittelt (Kapitel 3.2).

3.1 Merkmalsextraktion

Anhand der für ein Pixel gegebenen Sentinel-2 Daten werden zur Definition von korrespondierenden Merkmalsvektoren die Reflektanzwerte der einzelnen Spektralkanäle als Merkmale betrachtet und in einem Vektor gespeichert. Bei der Betrachtung von multitemporalen Sentinel-2 Daten wird der Merkmalsvektor über die Reflektanzwerte der einzelnen Spektralkanäle für alle betrachteten Zeitpunkte definiert.

Im Rahmen dieser Arbeit werden Reflektanzwerte betrachtet, welche zu den Spektralkanälen C2 (zentrale Wellenlänge: 490 nm), C3 (560 nm), C4 (665 nm), C5 (705 nm), C6 (740 nm), C7 (783 nm), C8a (865 nm), C11 (1610 nm) und C12 (2190 nm) korrespondieren. Reflektanzwerte, wel-

che zu den Spektralkanälen C1 (443 nm), C9 (945 nm) und C10 (1375 nm) korrespondieren, werden nicht berücksichtigt, da sie Bereiche im elektromagnetischen Spektrum abdecken, in denen die atmosphärische Durchlässigkeit nur gering ist oder der Wasserdampf das Verhalten dominiert. Der Spektralkanal C8 (842 nm) wird nicht berücksichtigt, da er mit dem Spektralkanal C8a überlappt, aber deutlich breiter und daher weniger charakteristisch ist.

Für die Reflektanzwerte aller betrachteten Spektralkanäle erfolgt eine atmosphärische Korrektur mittels der Sen2Cor Software (<http://step.esa.int/main/third-party-plugins-2/sen2cor/>).

3.2 Klassifizierung

Bei der Klassifizierung wird auf eine überwachte Klassifizierung fokussiert, d.h. anhand von repräsentativen Trainingsdaten wird ein Klassifizierungsverfahren trainiert. Erst danach kann eine Klassifizierung von weiteren Merkmalsvektoren durchgeführt werden. Im Rahmen dieser Arbeit werden verschiedene gängige Klassifizierungsverfahren verwendet.

3.2.1 Nearest-Neighbor-Klassifikator

Beim Nearest-Neighbor-Klassifikator (NN) erfolgt kein Training im eigentlichen Sinn. Vielmehr wird jeder zu klassifizierende Merkmalsvektor mit allen Merkmalsvektoren aus den Trainingsdaten verglichen, wozu oftmals der Euklidische Abstand als Ähnlichkeitsmetrik verwendet wird, und es wird dann die Klassenzugehörigkeit des ähnlichsten Merkmalsvektors aus den Trainingsdaten zugewiesen. Demzufolge ist es nicht erforderlich, eine Parameterschätzung durchzuführen oder vorab bestimmte Modellannahmen zu treffen. Allerdings wirkt sich gerade eine große Menge an durchzuführenden Vergleichen negativ auf den Rechenaufwand aus, da dieser dann in der Regel beachtlich ansteigt.

3.2.2 Naiver Bayes-Klassifikator

Beim naiven Bayes-Klassifikator (NB) handelt es sich um ein statistisches Klassifizierungsverfahren, welchem ein probabilistisches Modell basierend auf dem Bayes'schen Theorem zugrunde liegt und bei welchem angenommen wird, dass alle betrachteten Merkmale statistisch unabhängig voneinander sind. In der Trainingsphase werden anhand der Trainingsdaten die Wahrscheinlichkeit des Auftretens von Klassenzugehörigkeiten sowie die Wahrscheinlichkeiten von Merkmalen für diese Klassenzugehörigkeiten geschätzt. Damit kann dann für jeden zu klassifizierenden Merkmalsvektor die wahrscheinlichste Klassenzugehörigkeit ermittelt werden.

3.2.3 Lineare Diskriminanz-Analyse

Bei der linearen Diskriminanz-Analyse (LDA) handelt es sich um ein probabilistisches Klassifizierungsverfahren, bei welchem in der Trainingsphase eine multivariate Gauß-Verteilung an die gegebenen Trainingsdaten angepasst wird, d.h. es werden für jede Klasse die Parameter einer Gauss-Verteilung geschätzt. Vereinfachend wird hierbei angenommen, dass für alle Klassen identische Kovarianzmatrizen vorliegen und somit lediglich die Mittelwerte variieren. Für jeden zu klassifizierenden Merkmalsvektor werden dann die Wahrscheinlichkeiten ausgewertet, mit denen dieser Merkmalsvektor zu den verschiedenen Klassen gehört, und es wird dementsprechend die wahrscheinlichste Klassenzugehörigkeit zugewiesen.

3.2.4 Random Forest

Bei einem Random Forest (RF) (BREIMAN 2001) besteht die Grundidee in der strategischen Kombination von vielen schwachen Hypothesen zu einer starken Hypothese. In der Trainingsphase wird über ein Bootstrap Aggregating („Bagging“) ein Ensemble von randomisierten Entscheidungsbäumen erzeugt. Hierbei wird jeder Entscheidungsbaum trainiert, indem eine sukzessive Aufteilung der jeweils betrachteten Trainingsdaten in immer kleinere Untermengen durchgeführt wird, so dass jede Untermenge „so rein wie möglich“ ist. Diese Aufteilung wird in Form einer Sequenz von Entscheidungen formalisiert. Für jeden zu klassifizierenden Merkmalsvektor wird dann eine Sequenz von Entscheidungen durchlaufen, bis ein Blatt des Entscheidungsbaumes mit einer entsprechenden Hypothese bezüglich einer Klassenzugehörigkeit erreicht wird. Eine Betrachtung der schwachen Hypothesen („Votes“) über alle Entscheidungsbäume führt zu Klassenwahrscheinlichkeiten und der Mehrheitsentscheid („Majority Vote“) liefert eine starke Hypothese für eine geeignete Zuweisung einer Klassenzugehörigkeit.

3.2.5 Support Vector Machine

Bei der Support Vector Machine (SVM) (CORTES & VAPNIK 1995) müssen keine Annahmen über die Verteilung der gegebenen Daten getroffen werden. Stattdessen basiert die SVM auf der Idee, dass ein Klassifizierungsergebnis insbesondere dann gut ist, wenn es die einzelnen Klassen sehr gut separieren kann. Letzteres wird dann erreicht, wenn in der Trainingsphase zwischen den Datenpunkten, welche durch die Merkmalsvektoren gegeben sind, eine Trennfläche derart gezogen wird, dass der kürzeste Abstand zu den Datenpunkten einer Klasse maximiert wird. In der ursprünglichen Version ist eine SVM ein binäres Klassifizierungsverfahren, das darauf trainiert wird, zwei Klassen linear zu separieren. Im hochdimensionalen Merkmalsraum entspricht dies dem Einpassen einer Hyperebene, welche die Trainingsdaten entsprechend der Klassen aufteilt. Diese lineare Trennbarkeit stellt die Grundlage der linearen SVM (SVM-lin) dar. Sind die Daten nicht linear separierbar, wird der sogenannte „Kernel-Trick“ verwendet, mit dem eine nicht-lineare Abbildung des Merkmalsraums in einen höherdimensionalen Merkmalsraum erfolgt, in dem die Daten linear separierbar sind. Hierzu wird oftmals eine radiale Basis-Funktion in Form einer Gauß-Funktion verwendet, was zu einer modifizierten SVM-Variante (SVM-rbf) führt. Eine Verallgemeinerung auf das Mehrklassen-Problem geschieht dadurch, dass mehrere binäre SVMs kombiniert werden. Hierbei kann z.B. für jedes Paar an Klassen eine eigene SVM trainiert werden, die entsprechende Merkmalsvektoren voneinander unterscheidet.

4 Experimente und Ergebnisse

Im Folgenden wird zunächst der verwendete Datensatz genauer beschrieben (Kapitel 4.1) und dann genauer auf die Bestimmung von Trainingsgebieten und Kontrollgebieten eingegangen (Kapitel 4.2). Anschließend werden die erzielten Ergebnisse vorgestellt (Kapitel 4.3).

4.1 Datensatz

Das betrachtete Gebiet ist in Abb. 2 dargestellt. Es hat eine Größe von $16 \text{ km} \times 16 \text{ km}$ und enthält die Stadt Köln und deren Umgebung. Mit einer Ground Sampling Distance von 20 m lassen

sich die entsprechenden Sentinel-2 Daten als Bildstapel repräsentieren, wobei für jeden betrachteten Spektralkanal ein Bild mit 800×800 Pixeln vorliegt. Da im Rahmen dieser Arbeit lediglich die Spektralkanäle C2, C3, C4, C5, C6, C7, C8a, C11 und C12 betrachtet werden, ergibt sich somit pro Zeitpunkt ein Bildstapel bestehend aus neun Bildern. Insgesamt liegen Sentinel-2 Daten für die Zeitpunkte des 05.05.2016, 21.05.2016, 16.08.2016 und 26.08.2016 vor. Anhand dieser Sentinel-2 Daten soll eine Klassifizierung entsprechend der Klassen *Siedlung*, *Industrie*, *Feld*, *Wald*, *Garten*, *Wiese* und *Wasser* durchgeführt werden.

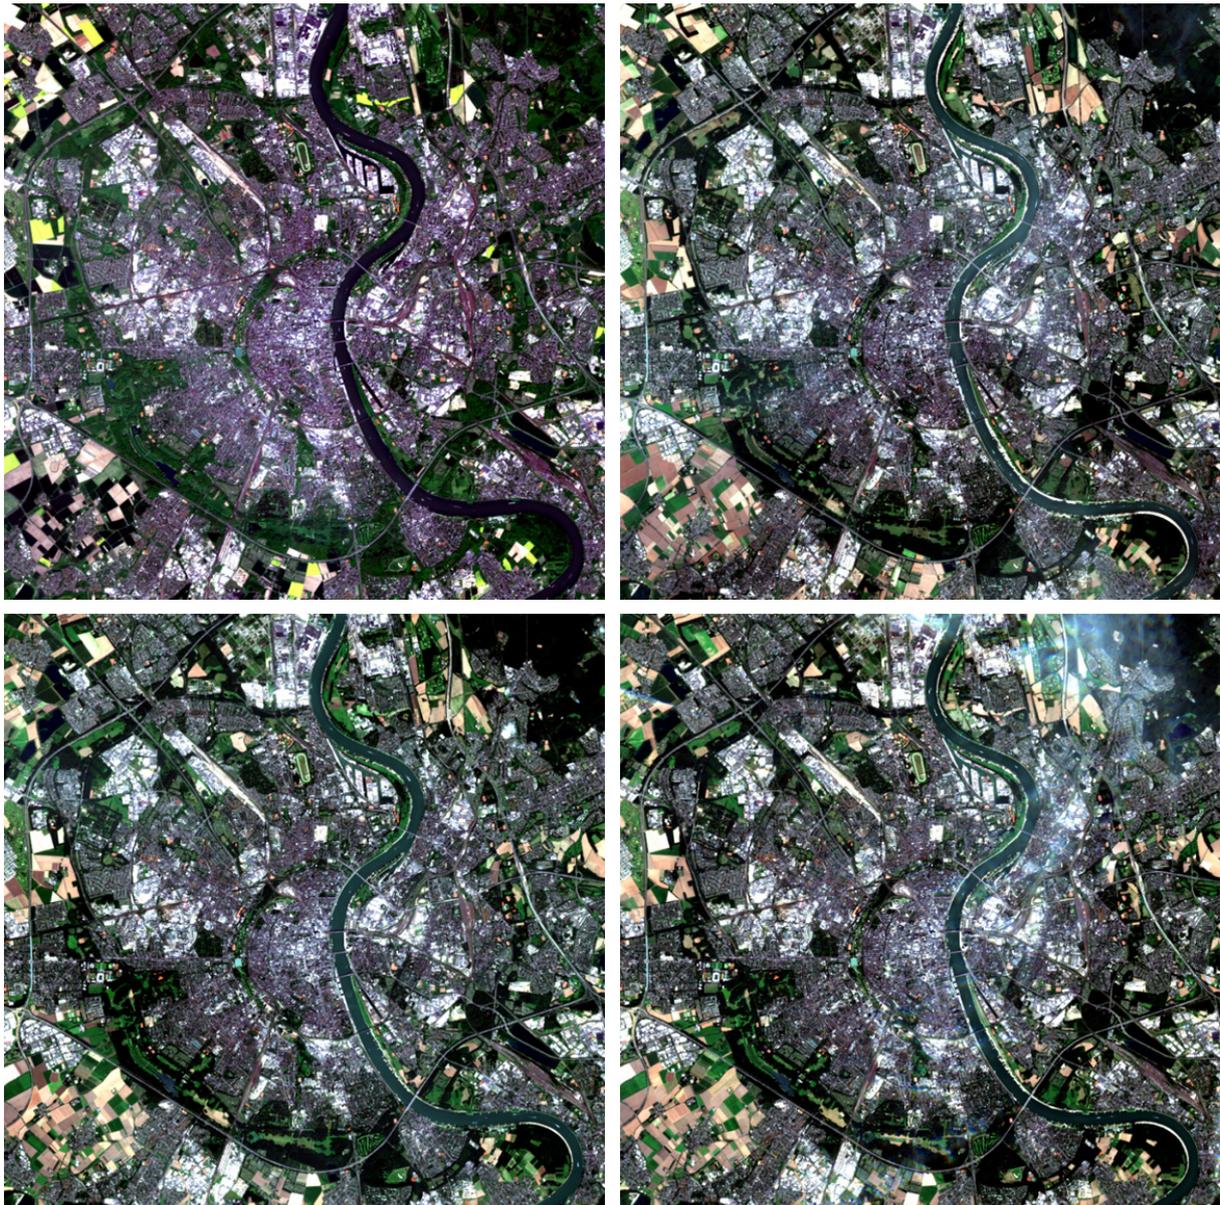


Abb. 2: Aus der Kanalkombination C4-C3-C2 abgeleitete Visualisierung für das betrachtete Gebiet um Köln zu den Zeitpunkten des 05.05.2016 (oben links), 21.05.2016 (oben rechts), 16.08.2016 (unten links) und 26.08.2016 (unten rechts)

4.2 Bestimmung von Trainingsgebieten und Kontrollgebieten

Zunächst wurden im Rahmen dieser Arbeit 34 Trainingsgebiete ausgewählt, welche den definierten Klassen entsprechen. Diese Trainingsgebiete umfassen insgesamt 4143 Pixel und entsprechen damit einer Fläche von 165,72 ha. Anhand dieser Trainingsgebiete mit bekannten Klassenzugehörigkeiten wurde pro Pixel ein Trainingsbeispiel bestehend aus dem entsprechenden Merkmalsvektor und der korrespondierenden Klassenzugehörigkeit definiert. Um eine quantitative Evaluierung der vorgestellten Methodik zu ermöglichen wurden zudem 57 Kontrollgebiete definiert, welche insgesamt 16859 Pixel und damit eine Fläche von 674,36 ha abdecken. Anhand der Kontrollgebiete mit bekannten Klassenzugehörigkeiten werden wiederum Testbeispiele definiert, die aus dem entsprechenden Merkmalsvektor und der korrespondierenden Klassenzugehörigkeit bestehen. Die entsprechenden Verteilungen über die einzelnen Klassen sind in Tab. 1 und Tab. 2 angegeben. Dabei wird deutlich, dass für die Klasse *Feld* prozentual gesehen sehr viele Trainingsbeispiele vorliegen, um die zeitliche Variabilität von Feldern möglichst gut abzudecken. Der hohe Anteil an Beispielen für die Klasse *Wasser* ist dadurch begründet, dass bei der Verwendung von statistischen Verfahren auch für diese Klasse eine gewisse Varianz vorliegt.

Tab. 1: Verteilung der Trainingsbeispiele für die definierten Klassen

Klasse	# Beispiele	Fläche [ha]	Anteil [%]
Siedlung	187	7,48	4,5
Industrie	207	8,28	5,0
Feld	2454	98,16	59,2
Wald	201	8,04	4,9
Garten	236	9,44	5,7
Wiese	233	9,32	5,6
Wasser	625	25,00	15,1
Σ	4143	165,72	100,0

Tab. 2: Verteilung der Testbeispiele für die definierten Klassen

Klasse	# Beispiele	Fläche [ha]	Anteil [%]
Siedlung	5226	209,04	31,0
Industrie	2972	118,88	17,6
Feld	2168	86,72	12,9
Wald	1830	73,20	10,9
Garten	2149	85,96	12,7
Wiese	1132	45,28	6,7
Wasser	1382	55,28	8,2
Σ	16859	674,36	100,0

4.3 Ergebnisse

Bei der Klassifizierung erfolgt eine Betrachtung von vier Fällen. Zunächst erfolgt jeweils eine separate Klassifizierung von Sentinel-2 Daten für die Zeitpunkte des 21.05.2016 und des 16.08.2016. Anschließend erfolgen eine Klassifizierung unter Berücksichtigung dieser beiden Zeitpunkte sowie eine Klassifizierung unter Berücksichtigung der Zeitpunkte des 05.05.2016, des 21.05.2016, des 16.08.2016 und des 26.08.2016. Die erzielten Klassifizierungsergebnisse sind in Tab. 3 bezüglich der Gesamtgenauigkeit, in Tab. 4 bezüglich des Kappa-Index und in Tab. 5 bezüglich des mittleren F_1 -Wertes angegeben, wobei als Klassifizierungsverfahren ein Nearest-Neighbor-Klassifikator (NN), ein naiver Bayes-Klassifikator (NB), eine lineare Diskriminanz-Analyse (LDA), ein Random Forest (RF), eine lineare SVM (SVM-lin) und eine nicht-lineare SVM (SVM-rbf) verwendet wurden. Anhand dieser Ergebnisse wird ersichtlich, dass für alle verwendeten Klassifizierungsverfahren die multitemporale Analyse insbesondere unter Berücksichtigung der Sentinel-2 Daten für alle vier Zeitpunkte zu einer deutlichen Verbesserung der Klassifizierungsergebnisse führt, wobei die Verbesserung bezüglich der Gesamtgenauigkeit, des Kappa-Index und des mittleren F_1 -Wertes jeweils bis zu >10% beträgt. Die besten Ergebnisse werden jeweils mit dem Nearest-Neighbor-Klassifikator erreicht und das jeweilige Klassifizierungsergebnis für das gesamte betrachtete Gebiet ist in Abb. 3 visualisiert.

Tab. 3: Gesamtgenauigkeit, die mit den verschiedenen Klassifizierungsverfahren erreicht wurde

berücksichtigte Zeitpunkte	NN	NB	LDA	RF	SVM-lin	SVM-rbf
21.05.	73,28%	60,63%	68,86%	71,15%	69,65%	70,85%
16.08.	79,09%	66,72%	70,08%	76,24%	76,67%	74,96%
21.05., 16.08.	80,54%	65,13%	73,55%	74,57%	75,81%	75,68%
05.05., 21.05., 16.08., 26.08.	83,62%	68,28%	75,65%	80,54%	80,98%	79,19%

Tab. 4: Kappa-Index, der mit den verschiedenen Klassifizierungsverfahren erreicht wurde

berücksichtigte Zeitpunkte	NN	NB	LDA	RF	SVM-lin	SVM-rbf
21.05.	68,15%	53,97%	62,93%	65,92%	64,22%	65,54%
16.08.	74,41%	60,28%	63,89%	70,94%	71,48%	69,49%
21.05., 16.08.	76,54%	58,88%	68,25%	69,49%	71,16%	70,95%
05.05., 21.05., 16.08., 26.08.	80,19%	62,38%	70,55%	76,72%	77,24%	74,99%

Tab. 5: Mittlerer F_1 -Wert, der mit den verschiedenen Klassifizierungsverfahren erreicht wurde

berücksichtigte Zeitpunkte	NN	NB	LDA	RF	SVM-lin	SVM-rbf
21.05.	76,03%	65,92%	72,00%	75,70%	74,12%	74,65%
16.08.	79,31%	66,42%	72,34%	76,87%	77,68%	75,89%
21.05., 16.08.	82,02%	67,58%	77,06%	77,47%	78,79%	79,17%
05.05., 21.05., 16.08., 26.08.	86,53%	70,42%	80,16%	83,61%	84,65%	82,47%

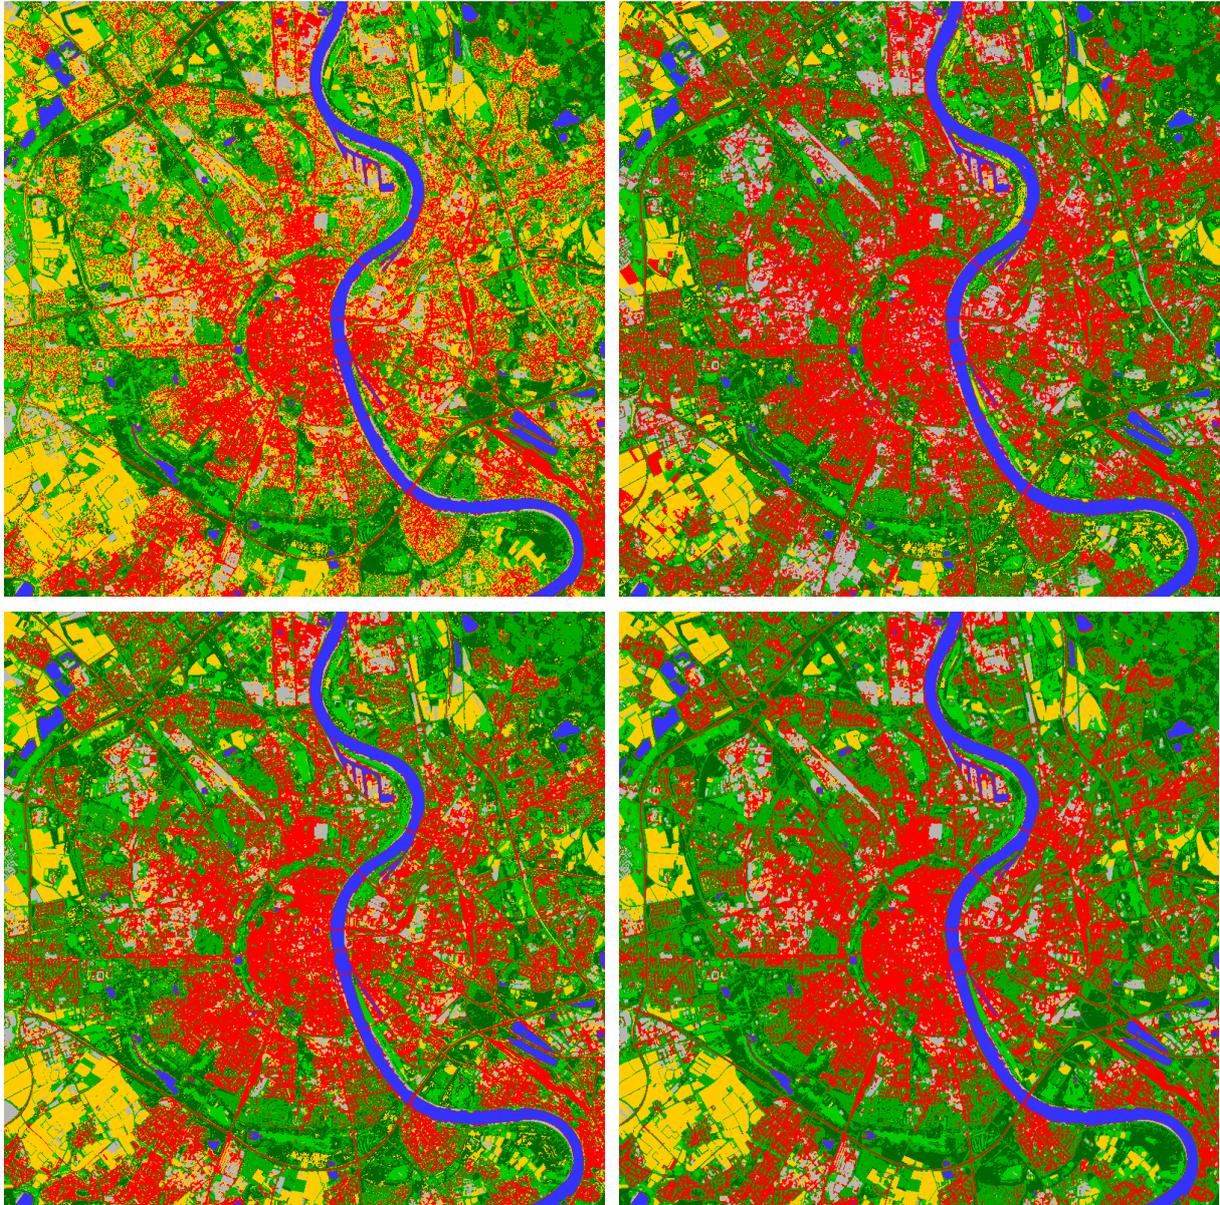


Abb. 3: Klassifizierungsergebnisse, die mit dem Nearest-Neighbor-Klassifikator erreicht wurden unter Berücksichtigung der Sentinel-2 Daten für den Zeitpunkt des 21.05.2016 (oben links), für den Zeitpunkt des 16.08.2016 (oben rechts), für die Zeitpunkte des 21.05.2016 und 16.08.2016 (unten links) und für die Zeitpunkte des 05.05.2016, des 21.05.2016, des 16.08.2016 und des 26.08.2016 (unten rechts). Die Farbcodierung erlaubt eine Unterscheidung gemäß der Klassen *Siedlung* (rot), *Industrie* (grau), *Feld* (gelb), *Wald* (dunkelgrün), *Garten* (grün), *Wiese* (hellgrün) und *Wasser* (blau)

5 Diskussion

Eine genauere Untersuchung der erzielten Klassifizierungsergebnisse (siehe Tab. 3, Tab. 4 und Tab. 5) zeigt, dass im Rahmen der durchgeführten Experimente die für den 21.05.2016 vorliegenden Sentinel-2 Daten weniger geeignet sind als die für den 16.08.2016 vorliegenden Sentinel-

2 Daten. Um die Ursache dafür zu ergründen, sind die jeweiligen Konfusionsmatrizen sowie daraus abgeleitete Evaluierungsmaße für die Ergebnisse des Nearest-Neighbor-Klassifikators in Tab. 6 und Tab. 7 angegeben. In diesen Tabellen wird erkennbar, dass für den 16.08.2016 insbesondere die Klassen *Feld*, *Garten* und *Siedlung* besser identifiziert werden können, während die Klasse *Wald* schlechter erkannt wird.

Tab. 6: Konfusionsmatrix für das Ergebnis des Nearest-Neighbor-Klassifikators unter Berücksichtigung der Sentinel-2 Daten für den Zeitpunkt des 21.05.2016

Klasse		Schätzung						
		Siedlung	Industrie	Feld	Wald	Garten	Wiese	Wasser
Referenz	Siedlung	3218	27	1455	0	524	1	1
	Industrie	159	1834	876	0	101	2	0
	Feld	0	1	1992	4	23	148	0
	Wald	1	0	4	1408	417	0	0
	Garten	0	0	298	6	1820	25	0
	Wiese	0	0	200	83	148	701	0
	Wasser	0	0	0	0	0	0	1382
Vollständigkeit		0,62	0,62	0,92	0,77	0,85	0,62	1,00
Korrektheit		0,95	0,98	0,41	0,94	0,60	0,80	1,00
F ₁ -Wert		0,75	0,76	0,57	0,85	0,70	0,70	1,00

Tab. 7: Konfusionsmatrix für das Ergebnis des Nearest-Neighbor-Klassifikators unter Berücksichtigung der Sentinel-2 Daten für den Zeitpunkt des 16.08.2016

Klasse		Schätzung						
		Siedlung	Industrie	Feld	Wald	Garten	Wiese	Wasser
Referenz	Siedlung	4264	140	51	12	758	0	1
	Industrie	611	2082	144	0	105	30	0
	Feld	382	43	1413	83	60	187	0
	Wald	0	0	242	1361	227	0	0
	Garten	10	4	13	41	2042	39	0
	Wiese	19	0	179	99	49	786	0
	Wasser	0	0	0	0	0	0	1382
Vollständigkeit		0,82	0,70	0,65	0,74	0,95	0,69	1,00
Korrektheit		0,81	0,92	0,69	0,85	0,63	0,75	1,00
F ₁ -Wert		0,81	0,79	0,67	0,79	0,76	0,72	1,00

Durch die Fusion von Sentinel-2 Daten, die zu verschiedenen Zeitpunkten erfasst wurden, wird besser berücksichtigt, dass das spektrale Verhalten verschiedener Objekte von zahlreichen Einflussfaktoren abhängt. Dadurch entsteht insbesondere bei der multitemporalen Analyse von Sentinel-2 Daten unter Berücksichtigung von vier Zeitpunkten eine deutliche Verbesserung der erzielten Klassifizierungsergebnisse (siehe Tab. 3, Tab. 4 und Tab. 5). Im Gegensatz zur Gesamtgenauigkeit, aus welcher lediglich eine globale Verbesserung der Güte des Klassifizierungsergebnisses ersichtlich wird, kann über den Kappa-Index auf eine bessere Trennbarkeit der einzelnen Klassen geschlossen werden, während der mittlere F_1 -Wert hier ein Indikator dafür ist, dass die Erkennungsraten über alle Klassen hinweg relativ gut sind. Zur genaueren Analyse der Verbesserung sind für die Ergebnisse des Nearest-Neighbor-Klassifikators unter Berücksichtigung der beiden Zeitpunkte des 21.05.2016 und des 16.08.2016 sowie unter Berücksichtigung aller vier Zeitpunkte die jeweiligen Konfusionsmatrizen sowie daraus abgeleitete Evaluierungsmaße in Tab. 8 und Tab. 9 angegeben. Beispielsweise zeigen ein Vergleich der Konfusionsmatrizen in Tab. 6 und Tab. 9 sowie ein Vergleich der daraus abgeleiteten Evaluierungsmaße der Vollständigkeit, der Korrektheit und des F_1 -Werts, dass durch die Berücksichtigung mehrerer Zeitpunkte insbesondere die Klassen *Feld* (+30% für den F_1 -Wert), *Wiese* (+24% für den F_1 -Wert) und *Wald* (+9% für den F_1 -Wert) besser erkannt werden können. Die durch die Berücksichtigung von vier statt zwei Zeitpunkten resultierende Verbesserung der Klassifizierungsergebnisse ist gemäß Tab. 8 und Tab. 9 durch eine verbesserte Erkennung der Klassen *Wiese* (+14% für den F_1 -Wert) und *Wald* (+7% für den F_1 -Wert) begründet. Erwartungsgemäß bestätigt die Betrachtung der klassenweisen Evaluierungsmaße auch, dass die Klasse *Wasser* generell einfach zu identifizieren ist, während die Klassen *Garten* und *Industrie* selbst unter der Berücksichtigung von Sentinel-2 Daten für alle vier betrachteten Zeitpunkte im Vergleich zu den anderen Klassen noch relativ schlecht erkannt werden.

Die Gegenüberstellung der Ergebnisse, welche mit verschiedenen Klassifizierungsverfahren erzielt wurden, zeigt auch, dass der naive Bayes-Klassifikator keine zufriedenstellenden Klassifizierungsergebnisse liefert. Dies liegt insbesondere daran, dass die Grundannahme von voneinander statistisch unabhängigen Merkmalen bei den vorliegenden Daten nicht erfüllt ist. Damit ist die Eignung des in der Trainingsphase angepassten probabilistischen Modells nur unzureichend für das betrachtete Klassifizierungsproblem gegeben. Im Vergleich dazu liefert die lineare Diskriminanz-Analyse deutlich bessere Ergebnisse, jedoch ist durch die Annahme von einer zugrundeliegenden multivariaten Gauß-Verteilung mit identischen Kovarianzmatrizen für alle Klassen immer noch eine starke Einschränkung gegeben, welche für die betrachteten Sentinel-2 Daten im Allgemeinen nicht vorliegt. Solche stark einschränkende Annahmen liegen beim Nearest-Neighbor-Klassifikator, beim Random Forest und bei der Support Vector Machine nicht vor, was in einer besseren Leistungsfähigkeit resultiert. Insbesondere der Nearest-Neighbor-Klassifikator ist für das vorliegende Klassifizierungsproblem geeignet, da die entsprechenden Ergebnisse immer noch besser sind als die eines Random Forest oder einer Support Vector Machine, obwohl für jene Klassifizierungsverfahren eine Optimierung von internen Parametern über einen geeigneten Suchraum erfolgt. Ferner lassen sich auch Vorteile einer linearen Support Vector Machine im Vergleich zur nicht-linearen Support Vector Machine feststellen.

Tab. 8: Konfusionsmatrix für das Ergebnis des Nearest-Neighbor-Klassifikators unter Berücksichtigung der Sentinel-2 Daten für die Zeitpunkte des 21.05.2016 und des 16.08.2016

Klasse		Schätzung						
		Siedlung	Industrie	Feld	Wald	Garten	Wiese	Wasser
Referenz	Siedlung	3932	28	285	1	979	0	1
	Industrie	397	1854	516	0	183	22	0
	Feld	0	3	1981	18	55	111	0
	Wald	0	0	55	1480	295	0	0
	Garten	3	0	16	11	2082	37	0
	Wiese	0	0	159	54	51	868	0
	Wasser	0	0	0	0	0	0	1382
Vollständigkeit		0,75	0,62	0,91	0,81	0,97	0,77	1,00
Korrektheit		0,91	0,98	0,66	0,95	0,57	0,84	1,00
F ₁ -Wert		0,82	0,76	0,76	0,87	0,72	0,80	1,00

Tab. 9: Konfusionsmatrix für das Ergebnis des Nearest-Neighbor-Klassifikators unter Berücksichtigung der Sentinel-2 Daten für alle vier betrachteten Zeitpunkte

Klasse		Schätzung						
		Siedlung	Industrie	Feld	Wald	Garten	Wiese	Wasser
Referenz	Siedlung	3973	35	72	0	1145	0	1
	Industrie	554	1957	265	1	192	3	0
	Feld	0	149	1955	0	25	39	0
	Wald	0	0	0	1660	166	4	0
	Garten	0	0	0	27	2092	30	0
	Wiese	0	0	32	19	3	1078	0
	Wasser	0	0	0	0	0	0	1382
Vollständigkeit		0,76	0,66	0,90	0,91	0,97	0,95	1,00
Korrektheit		0,88	0,91	0,84	0,97	0,58	0,93	1,00
F ₁ -Wert		0,81	0,77	0,87	0,94	0,72	0,94	1,00

6 Zusammenfassung und Ausblick

In diesem Beitrag wurde die multitemporale Analyse von Sentinel-2 Daten bezüglich diverser Landbedeckungs- und Landnutzungsklassen behandelt. Ausgehend von den Reflektanzwerten der einzelnen Spektralkanäle wurde mittels verschiedener Klassifizierungsverfahren eine semantische Interpretation eines betrachteten Gebiets durchgeführt, wobei die für verschiedene Zeitpunkte vorliegenden Sentinel-2 Daten separat und in Kombination betrachtet wurden. Die erzielten Ergebnisse zeigten eine deutliche Verbesserung der Klassifizierungsergebnisse für den Fall

einer multitemporalen Analyse von Sentinel-2 Daten im Gegensatz zur Berücksichtigung von Sentinel-2 Daten für lediglich einen Zeitpunkt. Dabei wurde ersichtlich, dass insbesondere die Klassen *Feld*, *Wiese* und *Wald* durch eine multitemporale Analyse besser erkennbar sind.

Im Rahmen weiterer Untersuchungen wird der Einbezug von Verfahren zur Merkmalsselektion angestrebt (KELLER et al. 2016), was eine Bewertung der Relevanz einzelner Merkmale bezüglich des betrachteten Klassifizierungsproblems erlaubt. Dadurch können die für das untersuchte Klassifizierungsproblem irrelevanten und zum Teil auch die redundanten Spektralbereiche identifiziert und dementsprechend bei der Klassifizierung ignoriert werden, was in der Regel zu einer deutlichen Verbesserung der Klassifizierungsergebnisse führt.

7 Literaturverzeichnis

- BREIMAN, L., 2001: Random forests. *Machine Learning*, **45**(1), 5-32.
- BRUZZONE, L., BOVOLO, F., PARIS, C., SOLANO-CORREA, Y.T., ZANETTI, M. & FERNÁNDEZ-PRIETO, D., 2017: Analysis of multitemporal Sentinel-2 images in the framework of the ESA Scientific Exploitation of Operational Missions. Proceedings of the 9th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp), 1-4.
- CORTES, C. & VAPNIK, V., 1995: Support-vector networks. *Machine Learning*, **20**(3), 273-297.
- GÓMEZ, C., WHITE, J.C. & WULDER, M. A., 2016: Optical remotely sensed time series data for land cover classification: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, **116**, 55-72.
- KARASIAK, N., SHEEREN, D., FAUVEL, M., WILLM, J., DEJOUX, J.F. & MONTEIL, C., 2017: Mapping tree species of forests in southwest France using Sentinel-2 image time series. Proceedings of the 9th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp), 1-4.
- KELLER, S., BRAUN, A. C., HINZ, S. & WEINMANN, M., 2016: Investigation of the impact of dimensionality reduction and feature selection on the classification of hyperspectral EnMAP data. Proceedings of the 8th IEEE Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), 1-5.
- KUKAWSKA, E., LEWINSKI, S., KRUPINSKI, M., MALINOWSKI, R., NOWAKOWSKI, A., RYBICKI, M. & KOTARBA, A., 2017: Multitemporal Sentinel-2 data – Remarks and observations. Proceedings of the 9th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp), 1-4.
- SOLANO-CORREA, Y.T., BOVOLO, F., BRUZZONE, L. & FERNÁNDEZ-PRIETO, D., 2017: Spatio-temporal evolution of crop fields in Sentinel-2 satellite image time series. Proceedings of the 9th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp), 1-4.
- SPOTO, F., SY, O., LABERINTI, P., MARTIMORT, P., FERNANDEZ, V., COLIN, O., HOERSCH, B. & MEYGREY, A., 2012: Overview of Sentinel-2. Proceedings of the 2012 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 1707-1710.
- ZHANG, T., SU, J., LIU, C., CHEN, W.H., LIU, H. & LIU, G., 2017: Band selection in Sentinel-2 satellite for agriculture applications. Proceedings of the 23rd International Conference on Automation and Computing (ICAC), 1-6.