John

Nutzung hyperspektraler Messtechnik (Teil 1) – Messtechnik, methodische Ansätze und Anwendungsbeispiele im markscheiderischen Kontext

Dr.-Ing. André John, andre.john@mabb.tu-freiberg.de
Technische Universität Bergakademie Freiberg, Fakultät für Geowissenschaften, Geotechnik und Bergbau, Institut für Markscheidewesen und Geodäsie, Fuchsmühlenweg 9 B, 09599 Freiberg

1. Einführung

Bildgebende, hyperspektrale Messtechnik ist eine leistungsfähige Technologie zur Aufnahme von detaillierten spektralen Informationen, welche in ganz unterschiedlichen Anwendungsszenarien genutzt werden kann. Hyperspektrale Messtechnik ermöglicht es, die chemische und physikalische Zusammensetzung von Materialien auf eine sehr präzise und detaillierte Weise zu untersuchen. Sie nutzt dabei das Prinzip, dass jedes Material und jeder Körper eine spezifische elektromagnetische Signatur aufweisen, die durch seine spektrale Reflektanz, Transmission oder Emission charakterisiert wird. Durch eine umfassende Analyse des elektromagnetischen Spektrums in hoher spektraler und räumlicher Auflösung können daher Informationen über den Zustand, die Struktur und die chemischen Eigenschaften von Objekten gewonnen werden. Beispielsweise lassen sich Materialien oder Substanzen identifizieren oder Veränderungen im Material oder in der Struktur eines Objekts feststellen.

Das Grundprinzip dieser Technik beruht dabei auf der Erfassung von Spektralinformationen in bestimmten Bereichen des elektromagnetischen Spektrums. Hierfür kommen spezielle Kameras, die aus einem spektralen Sensor und einem optischen System bestehen, zum Einsatz. Der spektrale Sensor kann das elektromagnetische Spektrum in viele schmale, aufeinanderfolgende Bänder unterteilen und dabei sehr präzise spektrale Informationen erfassen. Das optische System dient dazu, dass reflektierte oder emittierte Licht des zu untersuchenden Objekts zu sammeln und auf den spektralen Sensor zu fokussieren. Als Ergebnis liefern diese Aufnahmesysteme dann i. d. R. Rasterbilder mit detaillierten spektralen Informationen für jedes Bildpixel.

Die wesentliche Abgrenzung zur multispektralen Messtechnik ist durch den deutlich höheren Informationsgehalt in hyperspektralen Aufnahmen gegeben, da multispektrale Messtechnik im Vergleich, Informationen nur in vergleichsweise wenigen, diskreten spektralen Bändern erfasst. Hyperspektrale Aufnahmen zeichnen sich durch eine deutlich höhere Dimensionalität und damit einhergehende Komplexität aus, so dass die Verarbeitung von hyperspektralen Daten grundsätzlich anspruchsvoller ist und in der Regel spezialisierte Algorithmen und Methoden in der Datenvorverarbeitung und Analyse erfordert, damit letztlich relevante Informationen aus den typischerweise großen Datenmengen extrahiert werden können.

Die Abbildung 1 zeigt anschaulich die Charakteristik der multispektralen und hyperspektralen Bildgebung im Vergleich. Die multispektrale Bildgebung (links) liefert Informationen nur zu wenigen, diskreten und diskontinuierlich verteilten Spektralbereichen, während die hyperspektrale Bildgebung (rechts) einen so genannten

Der Einsatz hyperspektraler Messtechnik hat in den letzten Jahren in ganz unterschiedlichen Fachdisziplinen immer mehr an Bedeutung gewonnen. In den Geowissenschaften ermöglicht der Einsatz hyperspektraler Sensoren zum Beispiel eine detailliertere Analyse und Überwachung unseres Naturraums. Aufgrund der zunehmenden Bedeutung der Thematik, auch in Hinblick auf die Bearbeitung typischer markscheiderischer Aufgabenstellungen, soll im Rahmen dieses zweiteiligen Beitrages eine systematische Einführung in die Thematik erfolgen. Im vorliegenden ersten Teil soll sowohl auf verschiedene Messprinzipien der Messtechnik, Unterschiede in der Aufnahmekonfiguration, die Datenbereitstellung, sowie grundlegende methodische Ansätze der Datenvorverarbeitung und Datenanalyse, eingegangen werden. Im kommenden zweiten Teil sollen dann Anwendungsbeispiele ausgesuchter Algorithmen und Fallstudien vorgestellt werden.

Use of hyperspectral measurement technology (part 1) – Measurement technologies, methodical approaches and application examples in mine surveying context

The use of hyperspectral measurement technology has become increasingly important in a wide variety of disciplines in recent years. In geosciences for example, the use of hyperspectral sensors enables a more detailed analysis and monitoring of our natural environment. Due to the increasing importance of the topic, also with regard to the processing of typical mine surveying tasks, this two-part article will provide a systematic introduction to the topic. In this first part, various measurement principles of the measurement technology, differences in the recording configuration, data provision, as well as basic methodological approaches to data preprocessing and data analysis will be discussed. In the upcoming second part, application examples of selected algorithms and case studies will be presented.

Schlagworte
Keywords

Fernerkundung
Remote sensing

hyperspektrale Messtechnik
hyperspectral measurement technology

hyperspektrale Datenanalyse
hyperspectral data analysis

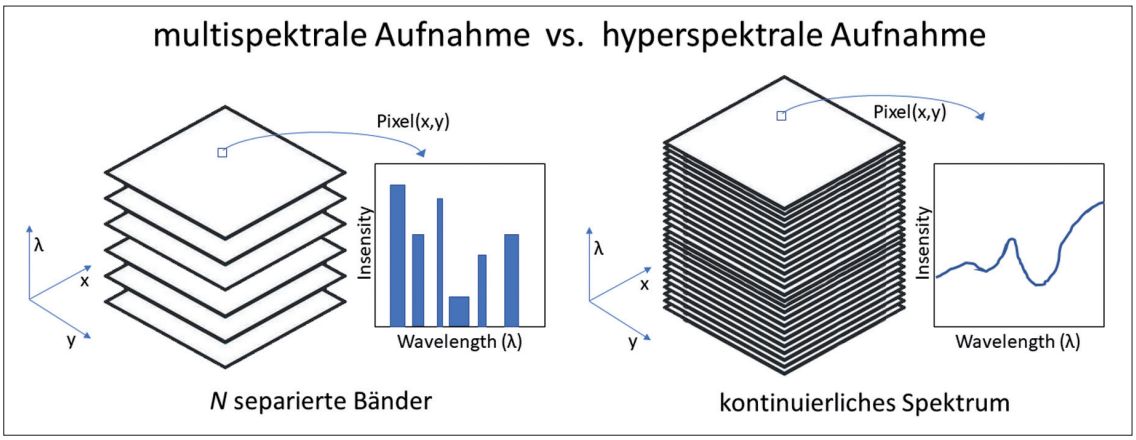

Abb. 1: Vergleich von multispektraler (links) vs. hyperspektraler (rechts) Bildgebung

‚Hypercube' aus einer großen Anzahl sehr schmaler zusammenhängender Spektralbänder erzeugt, so dass im Ergebnis für jedes Pixel ein kontinuierliches Spektrum im jeweiligen Wellenlängenbereich der genutzten Hardware (Hyperspektralkamera) vorliegt.

Der Einsatz hyperspektraler Messtechnik hat in den letzten Jahren immer mehr an Bedeutung gewonnen und ist heute neben den Geowissenschaften, auch in einer Vielzahl anderer Anwendungsbereiche wie der Landwirtschaft, der Lebensmittelindustrie, der Medizin, der Recyclingindustrie, der Sicherheitskontrolle oder auch der Forensik anzutreffen. In der Landwirtschaft wird sie z. B. genutzt um die Qualität von Böden zu verbessern oder Ernteerträge zu optimieren, indem relevante Parameter wie z. B. die Chlorophyll-Konzentration der Pflanzen oder der Nährstoffeintrag in den Boden durch Düngung besser überwacht werden können [1]. In der Lebensmittelindustrie kommt sie z. B. zur Qualitätskontrolle zum Einsatz, da aus den Reflektanzspektren von Lebensmitteln deren Frische, Reifegrad und Zusammensetzung bestimmt werden kann [2], [3]. Die Recyclingindustrie nutzt hyperspektrale Aufnahmen z. B. um Materialien wie z. B. Kunststoffe, Papier, Metalle und Glas genauer zu identifizieren und zu sortieren, was letztendlich zu einer höheren Recyclingrate und einer Verringerung der Menge an Abfall, die auf der Deponie landet, führt [4], [5]. In der Medizin trägt die hyperspektrale Messtechnik u. a. dazu bei, dass Krankheiten früher und genauer diagnostiziert werden können, da Messungen der elektromagnetischen Signatur von Geweben, Blut und anderen biologischen Proben die Entdeckung von Krebszellen oder anderen Erkrankungen bereits in frühen Stadien ermöglicht [6], [7]. In der Sicherheitskontrolle wird Hyperspektraltechnik z. B. zur Erkennung von gefährlichen Substanzen wie Sprengstoffen, Drogen oder gefälschten Dokumenten eingesetzt [8], [9], [10] und die Forensik nutzt sie u.a. für die Untersuchung von Tatorten, da die hyperspektrale Bildgebung es ermöglicht, Spuren und Materialien zu identifizieren und zu unterscheiden, die mit bloßem Auge nicht erkennbar wären [11], [12].

In den Geowissenschaften ermöglicht der Einsatz hyperspektraler Sensoren Forschern, detailliertere Informationen über die Erdoberfläche bzw. unsere Umwelt zu sammeln und bietet so viele Vorteile bei der Kartierung, Analyse und Vorhersage von geowissenschaftlichen Phänomenen. Der Kern aller Anwendungen ist die Analyse bzw. die Überwachung unseres Naturraums, welcher durch die Faktoren Klima, Gestein, Boden, Relief, Wasserhaushalt, Vegetation und Mensch bestimmt wird. Ein Versuch die Anwendungen hyperspektraler Sensoren in den Geowissenschaften zu kategorisieren, ist die Klassifizierung in folgende Anwendungsbereiche:

I. Boden- & Gesteinskunde: Hier werden hyperspektrale Sensoren eingesetzt, um die Zusammensetzung und Struktur von Böden und Gesteinen zu kartieren. Diese Informationen sind z. B. wichtig für die Exploration von Rohstoffvorkommen, sowie für die Bewertung von Umweltgefahren wie Bodenkontaminationen oder Erosionsprozesse.

II. Vegetationskunde: In diesem Bereich werden hyperspektrale Sensoren verwendet, um die Vegetationsbedeckung umfassend zu analysieren und zu überwachen und insbesondere um Aussagen über die Vitalität der Vegetation abzuleiten. Anwendungen in dieser Kategorie überschneiden sich teilweise auch mit landwirtschaftlichen Anwendungen. Durch die Analyse der spektralen Signaturen von Pflanzen können Forscher z. B. Krankheiten erkennen und deren Ausbreitung verhindern aber auch unterschiedliche Pflanzenarten können differenziert werden bzw. Aussagen zu ihrem Entwicklungsstand können abgeleitet werden.

III. Gewässerkunde: Hyperspektrale Sensoren werden verwendet, um die physikalischen und chemischen Eigenschaften von Gewässern zu analysieren. Dazu gehört die Wassertemperatur, die Trübung und der Nährstoffgehalt. Diese Informationen sind wichtig für die Überwachung der Gewässerqualität und die Vorhersage von Umweltgefahren wie Algenblüten oder Ölverschmutzungen.

IV. Geologie & Geomorphologie: In dieser Kategorie werden hyperspektrale Sensoren verwendet, um geologische Formationen und geomorphologische Merkmale zu kartieren. Dazu gehören beispielsweise Störungszonen, Felsformationen, Krater und Gletscher. Diese Informationen haben z. B. eine hohe Relevanz für die Erforschung der Erdgeschichte und für die Vorhersage von Naturgefahren wie Erdbeben und Vulkanausbrüchen.

V. Atmosphärenkunde: Verwendung hyperspektraler Sensoren, um die Zusammensetzung und Struktur der Atmosphäre zu analysieren. Dazu gehören beispielsweise die Konzentrationen von Treibhausgasen wie Kohlenstoffdioxid und Methan, sowie die Aerosolbelastung. Solche Informationen sind z. B. wichtig für die Erforschung des Klimawandels oder die Vorhersage von Wetterphänomenen.

Eine strikte Einteilung von Anwendungen in diese Kategorien ist jedoch nicht immer eindeutig möglich, da die Einflussfaktoren, durch welche unser Naturraum bestimmt wird, miteinander in Wechselwirkung stehen und sich gegenseitig beeinflussen, so dass sich die Anwendungsbereiche natürlich immer auch überschneiden können.

Eine der wichtigsten Anwendungen, im Kontext von Markscheidewesen und Bergbau, ist die Kartierung von geologischen Materialien und Strukturen, und insbesondere die Lagerstättenexploration. Die hyperspektrale Bildgebung ermöglicht es, verschiedene Mineralien und Gesteinstypen auf der Grundlage ihrer spektralen Signaturen zu identifizieren. Diese Signaturen sind einzigartig für jedes Material und können dazu genutzt werden, es von anderen Materialien zu unterscheiden. So können Geologen beispielsweise genauere Karten von geologischen Materialien und Strukturen erstellen, was dann wiederum bei der Entdeckung von Rohstoffvorkommen wie Erz, Kohle oder Öl hilft, da bestimmte Mineralien und Gesteinstypen auf spezifische Rohstoffe hinweisen können. [13] gibt einen Überblick zu geologischen Anwendungen und in [14] wird insbesondere die Lagerstättenexploration thematisiert. [15], [16], [17], [18], [19], [20] sind darüber hinaus einige beispielhafte Anwendungen in diesem Bereich.

Die Umweltüberwachung ist ein weiterer großer Anwendungsbereich der auch im Markscheidewesen und Bergbau eine wichtige Rolle spielt, da die Gewinnung von Bodenschätzen unter Umständen erhebliche Auswirkungen auf die Umwelt haben kann. Um mögliche Auswirkungen zu überwachen und zu minimieren, müssen entsprechende Maßnahmen ergriffen werden, wobei der Einsatz hyperspektraler Messtechnik hierfür ein hilfreiches Werkzeug darstellen kann. Im Allgemeinen werden in der Umweltüberwachung hyperspektrale Sensoren für die Analyse und das Monitoring von Veränderungen in Vegetation, Böden und Gewässern genutzt, um beispielsweise Gewässerqualitäten [21], [22], [23] oder Veränderungen der Vegetation [24], [25], [26], [27] zu erkennen bzw. um entsprechende Prozesse zu überwachen. Aber auch in der Gefahrenabwehr, z. B. bei der Erkennung von Ölverschmutzungen im Meer [28], [29] oder dem Küstenschutz bzw. der Küstenüberwachung [30], [31] kommen hyperspektrale Sensoren zum Einsatz. Mit der Anwendung hyperspektraler Sensorik im Bergbau im speziellen beschäftigt sich z. B. [32], [33] und [34].

Aufgrund der beschriebenen, vielseitigen Einsetzbarkeit hyperspektraler Technologien, sowie der zunehmenden Bedeutung der Thematik, auch in Hinblick auf die Bearbeitung typischer markscheiderischer Aufgabenstellungen, soll im Rahmen dieses Beitrags eine systematische Einführung in die Thematik erfolgen. Dabei soll sowohl auf verschiedene Messprinzipien der Messtechnik, Unterschiede in der Aufnahmekonfiguration, sowie die Datenbereitstellung, eingegangen werden. Darüber hinaus sollen grundlegende methodische Ansätze der Datenvorverarbeitung und Datenanalyse vorgestellt werden. Anwendungen ausgesuchter Algorithmen in Fallstudien sollen dann im kommenden Teil 2 des Beitrages gezeigt werden.

2. Methodik

2.1. Datenerfassung und -speicherung

Die hyperspektrale Datengewinnung kann grundsätzlich in verschiedenen Skalen bzw. aus unterschiedlichen Perspektiven erfolgen. Man unterscheidet hierbei im Wesentlichen folgende Aufnahmekonfigurationen:

- **Satellitenbasiert:** Satellitenbasierte Aufnahmesysteme ermöglichen aufgrund der Flughöhe ihrer Trägersysteme eine große räumliche Abdeckung und erlauben so die Erfassung von hyperspektralen Bildern aus dem Weltraum auf großem Maßstab. Satellitenmissionen wie EO-1 (Earth Observing-1) mit dem Hyperion-Sensor, das deutsche EnMAP (Environmental Mapping and Analysis Program) oder Terra mit dem MODIS (Moderate-resolution Imaging Spectrodiameter) Instrument sind Beispiele für satellitenbasierte hyperspektrale Messsysteme.
- **Flugzeugbasiert:** Flugzeuggetragene Systeme bieten die Möglichkeit, hyperspektrale Bilder mit höherer räumlicher und spektraler Auflösung im Vergleich zu Satellitensystemen zu erfassen. Flugzeugbasierte hyperspektrale Messsysteme sind i. d. R. auf spezifische Forschungsmissionen oder Überwachungsaufgaben abgestimmt. Sie ermöglichen eine gezielte Abdeckung und flexible Aufnahmepläne. AVIRS (Airborne Visible/Infrared Imaging Spectrometer), CASI (Compact Airborne Spectrographic Imager), AISA (Airborne Imaging Spectrometer for Applications) oder HySpex-Airbornesysteme sind Beispiele für flugzeuggetragene Messsysteme.
- **UAV-basiert:** UAVs (Unmanned Aerial Vehicles), auch bekannt als Drohnen, gewinnen als Trägersystem für hyperspektrale Sensoren immer mehr an Bedeutung. UAVs bieten eine kostengünstige und flexible Möglichkeit, hyperspektrale Bilder auf regionaler oder lokaler Ebene mit hoher räumlicher Auflösung zu erfassen. Viele der flugzeuggetragenen Systeme sind im Prinzip auch für die Verwendung auf UAVs geeignet, wobei natürlich vorwiegend besonders kompakte und leichte Systeme auf UAVs zum Einsatz kommen.
- **Terrestrisch:** Terrestrische Feldmessungen beziehen sich auf die Aufnahme hyperspektraler Bilder vom Boden aus. Hierbei werden i. d. R. hyperspektrale Kameras auf Stativen oder Fahrzeugen montiert und Bilder werden im Nahbereich erfasst. Diese Konfiguration ermöglicht eine sehr hohe räumliche Auflösung und detaillierte Analysen von kleinskaligen Objekten oder Bereichen. In der Regel haben alle gängigen Hersteller (z. B. HySpex, Specim, Cubert etc.) auch für den terrestrischen Einsatz geeignete Messsysteme im Portfolio.
- **Laborbasiert:** Hyperspektrale Bilder können natürlich auch im Labor aufgenommen werden, um kontrollierte Bedingungen und präzise Messungen zu gewährleisten. Dies geschieht z. B. bei der Untersuchung von Materialproben, wie Handstücken oder Bohrproben. Labormessungen bieten eine hohe Kontrolle über die Aufnahmeparameter bei der Erfassung der spektralen Charakteristik von Materialien und werden u. a. bei der Generierung von hyperspektralen Referenzbibliotheken, wie z. B. die USGS High Resolution Spectral Library [35] oder die ECOSTRESS Spectral Library [36], verwendet.

Darüber hinaus existieren drei grundsätzliche Ansätze um hyperspektrale Information zu erfassen. Das ist das Punkt-Scanning, das Linien-Scanning und das Flächen-Scanning (Abbildung 2).

Beim Punkt-Scanning (Abb. 2a) wird das Spektrum eines einzelnen Punktes (Pixels) gemessen. Für die Generierung eines hyperspektralen Bildes mit Hilfe eines Punktspektrometers müssen daher alle Punkte des regelmäßigen Bild-Rasters nacheinander erfasst werden. D. h. nachdem ein Punkt erfasst wurde, bewegt sich der Scanner zum nächsten Punkt und so weiter. Punkt-Scanning-Systeme bieten eine hohe spektrale Auflösung, erfordern jedoch im Vergleich eine längere Erfassungszeit.

Beim Linien-Scanning (Abb. 2b) wird eine ganze Zeile von Punkten gleichzeitig abgetastet. Der Scanner bewegt sich in einer Linie über das Untersuchungsobjekt, während er die spektralen Informationen für jeden Punkt entlang der Linie erfasst. Nachdem eine Zeile abgetastet wurde, wird der Scanner zur nächsten Zeile bewegt. Dieser Vorgang wird wiederholt, bis alle Zeilen abgetastet sind und ein hyperspektrales Bild entsteht. Linien-Scanning-Systeme sind erwartungsgemäß schneller als Punkt-Scanning-Systeme. In der Regel wird diese Konfiguration verwendet, wenn sich entweder das Objekt oder der Sensor relativ zueinander bewegen, wie im Falle von satellitengetragenen Systemen oder auch von Förderbandsystemen.

Beim Flächen-Scanning (Abb. 2c) werden ganze Flächen gleichzeitig abgetastet. Hierfür werden Matrixsensoren verwendet. Diese Sensoren bestehen aus einer Anordnung von Detektoren, die unterschiedliche spektrale Bandbereiche abdecken. Flächen-Scanning-Systeme ermöglichen eine schnelle Erfassung von hyperspektralen Bildern, jedoch sind diese Systeme aufgrund der Komplexität der verwendeten Detektorsysteme technisch anspruchsvoll und im Vergleich teurer.

Alle drei Systeme haben ihre Vor- und Nachteile, so dass die konkrete Wahl eines Ansatzes letztlich immer von den spezifischen Anforderungen der geplanten Anwendung bzw. der verfügbaren Hardware abhängig ist.

Für die Speicherung hyperspektrale Bilder gibt es verschiedene Datenspeicherformate, die speziell für die Verarbeitung und Analyse dieser Art von Daten entwickelt wurden. Das ENVI-Dateiformat ist eines der am häufigsten verwendeten Dateiformate für hyperspektrale Bilder. Es besteht aus zwei Dateien: einer Bilddatei die die spektralen Daten im BIL-, BSQ- oder BIP-Schema enthält und einer zugehörigen Header-Datei im ASCII-Format, welche die Metadaten wie die spektrale Kalibrierung, die räumliche Auflösung und andere Informationen enthält. Die Unterschiede der drei Speicherschemas (BIL, BSQ, BIP) können wie folgt zusammengefasst werden:

• **BIL (Band Interleaved by Line):** Beim BIL-Schema werden die Daten Band für Band für jede Zeile des Bildes gespeichert. Das bedeutet, dass die Pixel der ersten Zeile zunächst für den ersten Kanal (Band) hintereinander gespeichert werden, gefolgt von den Daten des zweiten Kanals, und so weiter. Das BIL-Schema erlaubt einen relativ effizienten räumlichen sowie spektralen Zugriff auf die Daten.

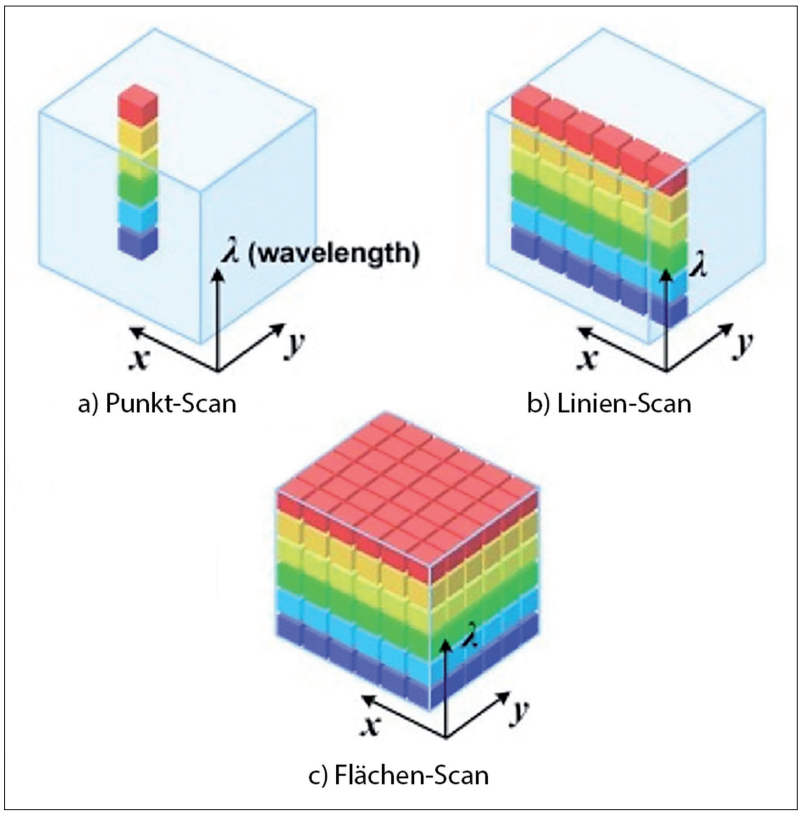

Abb. 2: Schematische Darstellung der drei grundsätzlichen Ansätze zur Generierung hyperspektraler Aufnahmen, adaptiert aus [37]

• **BSQ (Band Sequential):** Im BSQ-Schema werden die Daten für jeden Kanal sequenziell gespeichert. Das heißt, alle Pixel für den ersten Kanal werden nacheinander gespeichert, gefolgt von den Pixeln für den zweiten Kanal und so weiter. Das BSQ-Format bietet eine gute Komprimierungseffizienz und erleichtert den sequenziellen Zugriff auf die Daten einzelner Kanäle. Es ist jedoch nicht effizient für Operationen, die alle Kanäle eines Pixels gleichzeitig verarbeiten müssen (räumlicher Zugriff).

• **BIP (Band Interleaved by Pixel):** Beim BIP-Schema werden die Daten für jeden Pixel im Bild hintereinander gespeichert. Das bedeutet, dass jeder Kanal des ersten Pixels gefolgt von den Daten des zweiten Pixels und so weiter, gespeichert wird. Das BIP-Format ermöglicht einen schnellen Zugriff auf die Daten für ein bestimmtes Pixel, da alle Kanäle für dieses Pixel direkt aufeinander folgen. Es eignet sich gut für Anwendungen, bei denen eine schnelle Verarbeitung der spektralen Information eines Pixels erforderlich ist (spektraler Zugriff).

Wenn die Art des späteren Zugriffs auf die Daten zunächst unklar ist, stellt das BIL-Schema i. d. R. den besten Kompromiss dar. Grundsätzlich lassen sich die Daten aber zu jeder Zeit auch in eine der anderen drei Speicherschemas konvertieren.

Eine mögliche Alternative zum ENVI-Format ist das HDF-Format (Hierarchical Data Format). HDF ist ein flexibles und erweiterbares Dateiformat, das für die Speicherung großer Mengen von wissenschaftlichen Daten, einschließlich hyperspektraler Bilder, entwickelt wurde. HDF ermöglicht die Organisation der Daten in Hierarchien und unterstützt verschiedene Datentypen sowie Metadaten. Für die hyperspektrale Bildgebung werden vor allem die spezifischen Varianten HDF4, HDF5 oder

NetCDF (Network Common Data Form) verwendet. Auf eine vollständige Darstellung aller möglichen Speicherformate, soll an dieser Stelle verzichtet werden, da die Wahl eines spezifischen Formats immer von den Anforderungen der Anwendung, der Kompatibilität mit der Hardware und den verwendeten Softwaretools sowie den Anforderungen an die Effizienz bei der Speicherung und Verarbeitung der hyperspektralen Daten abhängt.

2.2. Datenvorverarbeitung

Wie bereits einführend festgestellt, sind für die Datenverarbeitung von hyperspektralen Aufnahmen spezialisierte Algorithmen und Methoden erforderlich. In diesem Abschnitt soll ein Überblick über wichtige Methoden der hyperspektralen Datenvorverarbeitung gegeben werden. Ziel der Datenvorverarbeitung ist die Bereinigung und Kalibrierung der erfassten Rohdaten um diese für die weitere Analyse und Interpretation vorzubereiten. Mögliche Ursachen für Fehler in den Rohdaten sind abgesehen von atmosphärischen oder topographischen Effekten, hauptsächlich sensorbedingte Fehlerquellen, wie ein diffuses Sensorrauschen, Streifenbildung, Smile- und Keystone-Effekt oder räumliche Fehlausrichtungen zwischen den Detektorarrays.

2.2.1. Geometrische Kalibrierung

Die geometrische Kalibrierung von hyperspektralen Aufnahmen beinhaltet die Korrektur von geometrischen Verzerrungen und ggf. die Zuordnung der Daten zu geografischen Koordinaten oder einem festen Bezugssystem, so dass eine präzise räumliche Registrierung der hyperspektralen Daten erreicht wird.

Auftretende geometrische Verzerrungseffekte sind z. B. der so genannte Smile-Effekt und der Keystone-Effekt (Abbildung 3). Der Smile-Effekt tritt auf, wenn das Bild in der Mitte verzerrt bzw. gekrümmt ist, ähnlich einem Lächeln. Dies resultiert aus Verzerrungen in der Optik oder in der Erfassungseinheit des hyperspektralen Sensors. Der Smile-Effekt kann zu einer Verschiebung der spektralen Kanäle führen und die Interpretation und Analyse der Daten erschweren. Für die Korrektur werden spezielle Algorithmen oder Modelle verwendet, die die Verzerrungen charakterisieren und kompensieren. Der Keystone-Effekt tritt auf, wenn das Bild eine Trapezform annimmt, anstatt eine rechteckige oder quadratische Form zu haben. Dies kann aufgrund von Schrägstellungen oder Neigungen des Sensors während der Aufnahme auftreten. Die Korrektur des Keystone-Effekts beinhaltet normalerweise die Anwendung von geometrischen Transformationen (Rotationen, Skalierungen oder Perspektivtransformationen), um das Bild in eine rechteckige Form zu bringen.

2.2.2. Radiometrische Kalibrierung

Die radiometrische Kalibrierung von hyperspektralen Aufnahmen beinhaltet die Umwandlung der elektrischen Signale (Rohdaten), die vom Sensor erfasst werden, in radiometrische Werte, die eine physikalische Bedeutung haben. Diese Kalibrierung ist entscheidend, um genaue und vergleichbare Messergebnisse zu erhalten. Die radiometrische Kalibrierung kann grundsätzlich folgende Prozessschritte enthalten:

- **Spektrale Kalibrierung:** Die spektrale Kalibrierung bezieht sich auf die genaue Zuordnung der spektralen Kanäle zu Wellenlängen. Hierbei werden Referenzmaterialien oder -lampen verwendet, um die spektrale Reaktion des Sensors zu kalibrieren. Dadurch wird sichergestellt, dass die gemessenen Wellenlängenwerte korrekt sind. In der Regel erfolgt diese Kalibrierung bereits durch den Hersteller der hyperspektralen Messtechnik.
- **Dunkelstrom-Subtraktion:** Als Dunkelstrom (dark current) bezeichnet man den Strom der im unbelichteten Zustand in jedem Bildpixel fließt. Dieser zeigt sich im hyperspektralen Bild als thermisches Rauschen, welches durch die Subtraktion des Dunkelstroms von den Rohdaten reduziert werden kann. Dadurch werden systembedingte Rauschanteile entfernt, die von der Sensorhardware stammen.
- **Flachfeld-Korrektur:** Die ungleichmäßige Ausleuchtung des Sensors wird ausgeglichen, indem die Rohdaten mit einem Flachfeld oder Referenzbild dividiert werden. Das Flachfeld repräsentiert das Ansprechverhalten des Sensors auf eine gleichmäßige Beleuchtung.

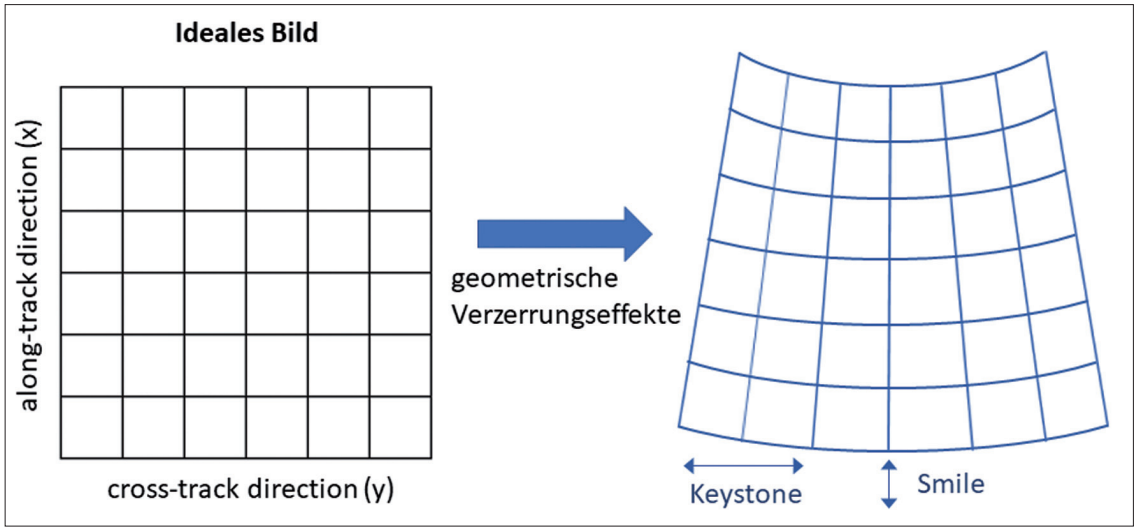

Abb. 3: Smile- und Keystone-Effekt in hyperspektraler Aufnahme

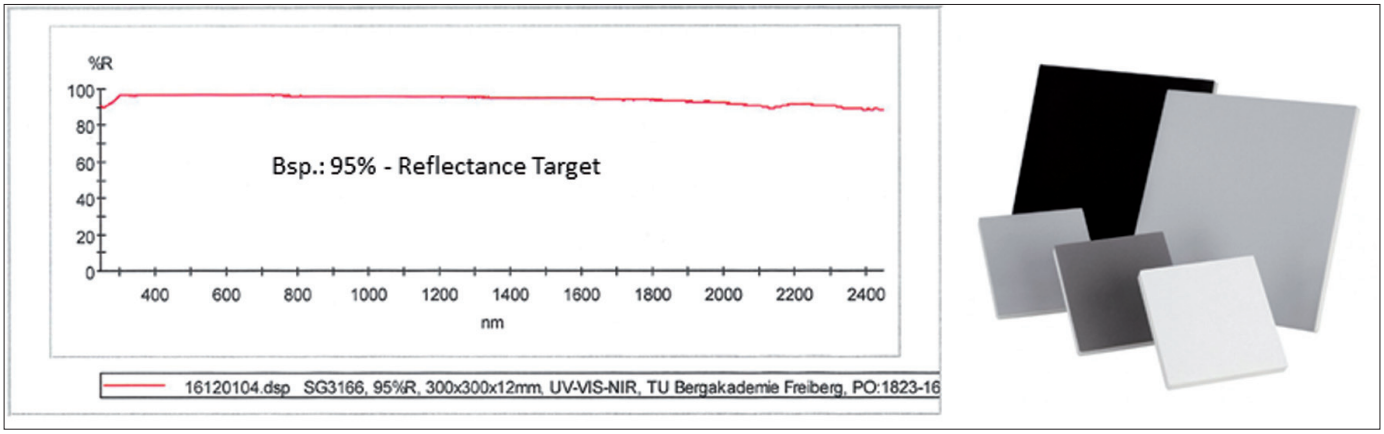

Abb. 4: Spectralon® Referenzziele verschiedener Reflexionsniveaus (rechts) und Reflexionskurve (eines 95%-Referenzziels für den spektralen Arbeitsbereich (Wellenlänge) 250 nm bis 2520 nm (links)

• **Streifenmusterkorrektur:** Streifenmuster-Effekte sind periodische Helligkeitsunterschiede bzw. Muster, die die Interpretation und Analyse erschweren. Sie werden durch systematische Fehler in der Erfassung oder der Signalverarbeitung verursacht. Zur Bereinigung dieser Effekte werden unter anderem spezielle Korrekturalgorithmen angewendet, die gezielt Streifenmuster erkennen und entfernen indem sie die Helligkeitsunterschiede anpassen. Aber auch die Anwendung von Rauschfilterungstechniken kann helfen, das Signal-Rausch-Verhältnis zu verbessern und damit Streifenmuster zu reduzieren.

• **Atmosphärenkorrektur:** Bei der Atmosphärenkorrektur geht es darum, die Auswirkungen der Atmosphäre auf die gemessenen Strahlungswerte zu berücksichtigen und zu korrigieren. Die Atmosphäre wirkt wie ein Filter, der bestimmte Wellenlängen absorbiert, streut oder reflektiert, was zu Veränderungen in den gemessenen hyperspektralen Daten führt. Die Atmosphärenkorrektur zielt also darauf ab, die tatsächliche Oberflächenreflexion/-emission zu rekonstruieren, indem atmosphärische Effekte entfernt werden.

• **Empfindlichkeitskalibrierung:** Die Empfindlichkeitskalibrierung bezieht sich auf die Umwandlung der Rohdaten in radiometrische Werte (tatsächliche Intensität). Hierbei werden die Rohdaten mit einer Kalibrierkurve oder einem Kalibrierkoeffizienten multipliziert, um die lineare Beziehung zwischen den elektrischen Signalen und den physikalischen Einheiten herzustellen.

• **Reflektanz-Kalibrierung:** Bei der Reflektanz-Kalibrierung werden die gemessenen Strahlungswerte in Einheiten der prozentualen oder absoluten Reflektanz skaliert um vergleichbare quantitative Informationen zu erhalten. Die Messung wird dadurch also unabhängig von der Quanteneffizienz des Aufnahmesystems und der Beleuchtung. Neben einem Dunkelstrombild wird hierfür eine so genannte Weißreferenz benötigt. Die Weißreferenz ist ein hyperspektrales Bild von einem nahezu spektral homogenen Referenzmaterial deren Reflexion für den Arbeitsbereich (Wellenlänge) der verwendeten Hyperspektralkamera exakt bekannt ist. Als Referenzmaterial wird z. B. Spectralon® der Firma Labsphere verwendet. Kalibrierte Referenzziele unterschiedlicher Reflexionsniveaus sind hierfür verfügbar (Abbildung 4). Mit Hilfe der Gleichung $I = R_\lambda^{Ref} \cdot \frac{I_0 - D}{W - D}$ kann dann die prozentuale Reflektanz I berechnet werden, dabei ist I_0 das gemessene Bild, D ist das Dunkelstrombild, W die Weißreferenz und R_λ^{Ref} die bekannte (nahezu homogene) wellenlängenabhängige Reflexion des Referenzmaterials.

2.2.3. Räumliches und Spektrales Resampling

Das räumliche und spektrale Resampling sind Techniken zur Anpassung der Auflösung von hyperspektralen Bildern um eine optimale Balance zwischen Auflösung, Datenmenge und Verarbeitungseffizienz zu finden und die hyperspektralen Daten an die spezifischen Anforderungen anzupassen. Beim räumlichen Resampling wird die räumliche Auflösung des hyperspektralen Bildes angepasst, indem die Pixelgröße geändert wird. Diese Technik wird verwendet, um das Bild an eine bestimmte Zielauflösung anzupassen. Beim spektralen Resampling wird die spektrale Auflösung angepasst, indem die Anzahl und damit auch die Breite der spektralen Kanäle verändert wird. Ziel ist auch hier die Anpassung an eine bestimmte spektrale Zielauflösung. Eine Reduktion der räumlichen bzw. spektralen Auflösung führt immer auch zu reduzierten Datenmengen.

2.2.4. Datenfusion

Die Datenfusion hyperspektraler Aufnahmen kann sich zum einen auf den Prozess der Kombination von Informationen aus verschiedenen hyperspektralen Bildern beziehen, um ein umfassenderes und aussagekräftigeres Bild oder eine vollständigere Darstellung der betrachteten Szene zu erhalten. Die hyperspektralen Aufnahmen können sich dabei in ihrer räumlichen Abdeckung (Aufnahmebereich) oder im Spektralbereich (Wellenlänge) unterscheiden. Bei der spektralen Datenfusion werden hyperspektrale Bilder von Kameras mit unterschiedlichen Spektralbereichen (Wellenlänge) miteinander kombiniert, um die spektrale Abdeckung zu verbessern. Hingegen geht es bei der räumlichen Datenfusion um die Kombination von Aufnahmen unterschiedlicher Auflösungen oder Aufnahmebereiche. Ziel dabei ist die

räumliche Genauigkeit und Qualität des hyperspektralen Bildes zu verbessern bzw. die räumliche Ausdehnung eines hyperspektralen Datensatzes zu erhöhen.

Zum anderen können referenzierte hyperspektrale Daten auch mit anderen referenzierten Datensätzen, wie z. B. 3D-Punktwolken fusioniert werden. Solche 3D-Punktwolken können aus LiDAR-Systemen stammen oder auch photogrammetrisch erzeugt werden. Diese Art der Datenfusion ermöglicht eine kombinierte Analyse von spektralen und geometrischen Informationen, was eine umfassendere und detailliertere Untersuchung der betrachteten Szene ermöglicht.

2.2.5. Feature-Extraktion & Dimensionsreduktion

Feature-Extraktion spielt eine wichtige Rolle bei der Verarbeitung von hyperspektralen Daten, insbesondere bei der Reduzierung von Redundanz und Dimensionalität. Hyperspektrale Bilder enthalten eine große Anzahl von spektralen Kanälen, die oft korreliert sind und daher redundante Informationen enthalten. Die Redundanz der Daten führt zu einer erhöhten Komplexität bei der Analyse und kann zu einer Überanpassung von Modellen führen. Die Feature-Extraktion zielt darauf ab, die wichtigsten und informativsten Merkmale aus den hyperspektralen Daten zu extrahieren und die Dimensionalität zu reduzieren. Durch die Identifizierung und Auswahl von Merkmalen, die die größte Varianz, Trennbarkeit oder Informationsgehalt aufweisen, können unnötige Informationen eliminiert und relevante Informationen hervorgehoben werden. Eine effektive Feature-Extraktion ermöglicht also zum einen eine effizientere Datenverarbeitung, da die Datenmenge reduziert wird, was letztlich zu schnelleren Berechnungen und einem verringerten Speicherbedarf führt. Und zum anderen hilft die Reduzierung der Dimensionalität die Wahrscheinlichkeit von Überanpassungen zu verringern und Modelle robuster zu machen. Darüber hinaus verbessert die Auswahl relevanter Merkmale die Interpretierbarkeit und Verständlichkeit der Daten, da nur Merkmale verwendet werden, die für die spezifische Anwendung von Interesse sind.

Es gibt sehr viele verschiedene Ansätze der Feature-Extraktion & Dimensionsreduktion, welche sich hinsichtlich ihrer Komplexität unterscheiden. Einen guten Überblick liefert z. B. [38], [39]. Die aufgrund ihrer relativen Einfachheit häufig verwendeten Methoden zur Dimensionsreduktion von hyperspektralen Datensätzen sind:

- **Hauptkomponentenanalyse / Principal Component Analysis (PCA):** Die PCA ist eine weit verbreitete Methode zur Dimensionsreduktion. Sie analysiert die statistische Korrelation zwischen den spektralen Bändern und transformiert die Daten in einen neuen Merkmalsraum, in dem die Hauptkomponenten die größte Varianz in den Daten repräsentieren. Durch die Auswahl einer Teilmenge der Hauptkomponenten können die Daten auf eine niedrigere Dimensionalität reduziert werden, während die wichtigsten Informationen beibehalten werden.
- **Minimum Noise Fraction (MNF):** MNF ist ein ähnlicher Ansatz wie PCA, der jedoch darauf abzielt, die rauschärmsten Komponenten zu extrahieren. Dies ermöglicht eine bessere Betonung relevanter Informationen in den Daten und eine Reduzierung des Rauschanteils.
- **Feature Selektion:** Anstelle einer systematischen Dimensionsreduktion können auch Feature-Selektions-Methoden verwendet werden, um eine relevante Teilmenge der ursprünglichen spektralen Kanäle auszuwählen. Diese Methoden bewerten die Relevanz jedes spektralen Kanals anhand verschiedener Kriterien wie Informationsgehalt, Klassentrennbarkeit oder Korrelation mit den Zielvariablen.

2.3. Datenanalyse

Nach der Datenvorverarbeitung können nun Methoden zur Analyse der vorverarbeitenden hyperspektralen Daten angewendet werden. Diese Methoden haben i. d. R. zum Ziel, die Daten zu klassifizieren bzw. anwendungsrelevante Informationen aus diesen zu extrahieren.

2.3.1. Extraktion repräsentativer spektraler Signaturen

Spektrale Signaturen beschreiben die Reflexionscharakteristik von Objekten bzw. Materialien in Abhängigkeit von der Wellenlänge. Sie werden genutzt um verschiedene Objektarten oder Materialien anhand ihrer charakteristischen Reflexionen in verschiedenen Wellenlängenbereichen des elektromagnetischen Spektrums zu identifizieren bzw. zu extrahieren. Die repräsentativen spektralen Signaturen einzelner „reiner" Materialien die in einer Aufnahme enthalten sind, werden auch als Endmember bezeichnet.

Die räumliche und spektrale Skale einer Aufnahme sind u. a. wichtige Faktoren bei der Extraktion repräsentativer spektraler Signaturen. Bei einer feinen räumlichen Auflösung, wie beispielsweise bei laborbasierten Aufnahmen aus kurzer Distanz, beschreibt ein einzelner Pixel eine nur sehr kleine Fläche, so dass auch kleinere Bestandteile, wie beispielsweise einzelne „reine" Mineralien, möglicherweise aufgelöst werden können, während bei gröberen räumlichen Auflösungen, wie beispielsweise bei satellitenbasierten Aufnahmen, die gemessenen spektralen Signaturen i. d. R. immer die durchschnittliche Zusammensetzung eines größeren Bereichs repräsentieren. Analog dazu ermöglicht eine höhere spektrale Auflösung, also eine größere Anzahl von schmaleren Bändern in einem bestimmten Wellenlängenbereich, die Unterscheidung feinerer spektraler Unterschiede bzw. Details im Reflexionsverhalten.

Grundsätzlich können also in einer hyperspektralen Aufnahme mehrere Materialien oder Objekte innerhalb eines einzelnen Pixels vorhanden sein, was letztlich zu einem gemischten spektralen Signal führt. Diese spektrale Mischung von Materialien, Substanzen oder Objekten in einem Pixel muss durch ein geeignetes lineares oder nicht-lineares Mischungsmodell beschrieben werden, um die Endmember und ihre Mischungsanteile ableiten zu können. Die Abbildung 5 zeigt eine Darstellung von möglichen, auftretenden Mischungsphänomenen bzw. Effekten:

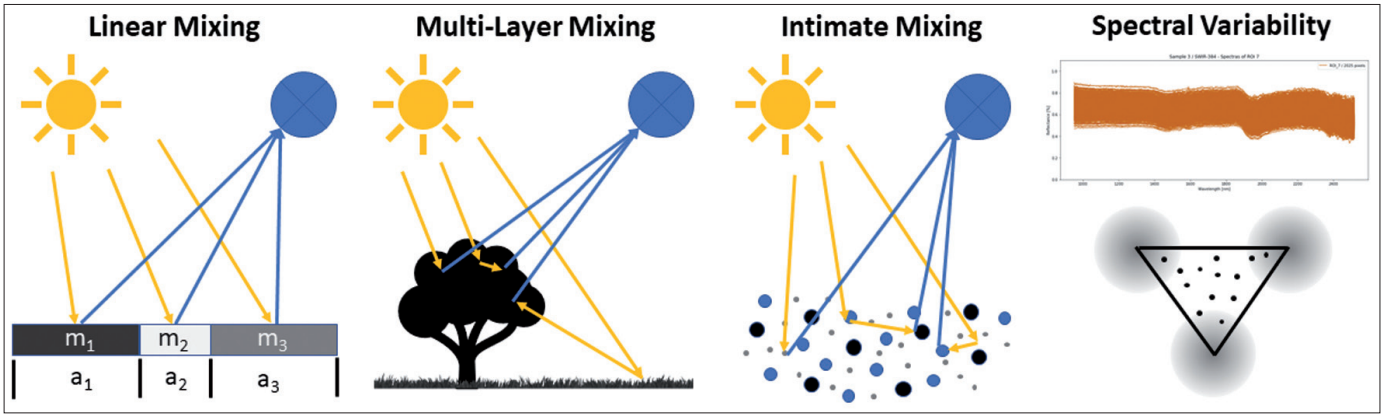

Abb. 5: Mischungsphänomene bzw. Effekte in der hyperspektralen Bildgebung

• **Lineares Mixing:** Das lineare Mixing geht davon aus, dass die spektrale Mischung in einem Pixel als lineare Kombination der spektralen Signaturen der einzelnen Endmember erfolgt. Es wird angenommen, dass es keine Wechselwirkungen oder nichtlineare Effekte zwischen den Endmembern gibt.

• **Multi-Layer Mixing:** Das Multi-Layer Mixing erweitert das lineare Mixing, indem es die Existenz mehrerer Schichten/Layer in einem Pixel berücksichtigt. Jede Schicht hat ihre eigenen spektralen Signaturen und Anteile. Die Mischung zwischen den Schichten kann als lineare Kombination oder als nicht-lineare Wechselwirkung modelliert werden.

• **Intimate Mixing:** Intimate Mixing beschreibt die Möglichkeit einer starken räumlichen Korrelation bzw. Interaktion zwischen den Endmembern. Es wird angenommen, dass die spektrale Mischung aufgrund von Nähe oder Überlappung der Materialien oder Substanzen stattfindet. Diese Art der Mischung wird i. d. R. als nicht-lineare Wechselwirkung modelliert.

• **Spectral Variability:** Die spektrale Variabilität bezieht sich auf die Variation der spektralen Signaturen eines bestimmten Materials oder Endmembers aufgrund von intraklassen- oder intraklassenbedingten Variationen, wie z. B. durch Änderungen der Umgebungsbedingungen (z. B. Schwankungen der Beleuchtung), der atmosphärischen Bedingungen (z. B. Wassergehalt in der Atmosphäre) und der inhärenten Variabilität innerhalb eines Materials. Die spektrale Variabilität wird i. d. R. ebenfalls mit nicht-linearen Ansätzen modelliert.

So genannte spektrale Unmixing Verfahren ermöglichen es, Informationen über die Bestandteile einer Szene für jedes Pixel aus den gemessenen Spektralsignaturen zu extrahieren und zu quantifizieren. Die Mischungsmodelle beschreiben dabei die Art und Weise, wie die spektrale Mischung der Materialien oder Substanzen in einem Pixel stattfinden. Der Prozess des spektralen Unmixing besteht dabei grundsätzlich aus zwei Hauptschritten, die Endmember Extraktions-Analyse (EEA) und die Schätzung der Endmemberanteile (Abundanz). Im Zuge der EEA wird als erstes versucht die Spektralsignaturen der „reinen" Materialien (Endmember), die in der Szene vorhanden sind, zu identifizieren. Das bedeutet EEA-Algorithmen zielen darauf ab, eine begrenzte Anzahl von Endmember zu bestimmen, die die beobachteten Spektren am wahrscheinlichsten erklären. Nach der Extraktion der Endmember ist der zweite Schritt dann die Schätzung der Endmemberanteile, also wie stark jeder Endmember zur Mischung in jedem Pixel beiträgt. Dies kann als ein Optimierungsproblem betrachtet werden, bei dem eine Mischung von Endmembern ermittelt wird, die die gemessenen Spektren am besten rekonstruiert. Man unterscheidet grundsätzlich lineare und nicht-lineare Unmixing Verfahren bzw. auch Kombinationen aus beiden. Dabei gehen die linearen Unmixing Ansätze immer davon aus, dass die Mischung der Endmember in den Pixeln durch lineare Zusammenhänge beschrieben werden können und durch Lösung von linearen Gleichungssystemen oder Fehlerminimierungsansätzen können dann die Anteile der Endmember (Abundanz) geschätzt werden. Lineare Unmixing-Verfahren stoßen allerdings an ihre Grenzen, wenn nicht-lineare Effekte oder Wechselwirkungen dominieren. In diesen Fällen können nicht-lineare Unmixing Ansätze notwendig sein. Diese deutlich komplexeren Ansätze setzen i. d. R. nicht-lineare Optimierungsalgorithmen oder maschinelles Lernen ein, um die spektralen Signaturen der Endmember und ihre Anteile zu schätzen.

In der praktischen Anwendung sind die linearen Ansätze jedoch immer noch am häufigsten anzutreffen. Die Gründe dafür sind zum einen die Einfachheit und Effizienz dieser Ansätze, was gerade bei der Verarbeitung großer Datenmengen oder der Echtzeitverarbeitung ein wichtiger Aspekt ist. Des Weiteren bieten lineare Modelle eine robuste, konsistente und reproduzierbare Schätzung der Endmember und ihrer Anteile und können auch bei leichter Verletzung der linearen Annahmen noch recht gute Ergebnisse liefern. Darüber hinaus spielt die deutlich höhere Verfügbarkeit und Unterstützung von linearen Unmixing Algorithmen in verfügbaren Softwarelösungen ebenfalls eine nicht unwesentliche Rolle.

Es existieren eine Reihe unterschiedlicher Ansätze, basierend auf verschiedenen Annahmen, Modellen und Algorithmen, um die Endmember und deren Anteile in hyperspektralen Daten zu schätzen. Die nachfolgenden Beispiele zeigen nur einige populäre lineare und nicht-lineare Verfahren bzw. Verfahrensansätzen für die Endmember-Extraktion (EEA) bzw. die Schätzung der Endmemberanteile (Abundanz). Es ist jeweils gekennzeichnet inwieweit die Verfahren für die EEA, die Bestimmung der Abundanz oder für beides genutzt werden können.

• Lineare Methoden:

• **Vertex Component Analysis (VCA) [EEA]:** Ein geometriebasierter Ansatz, der versucht, die Endmember durch die Suche nach den Eckpunkten im spektralen Raum zu extrahieren [40].

• **N-FINDR [EEA]:** Ein iterativer Algorithmus, der versucht, die Endmember zu identifizieren, indem er schrittweise die am wenigsten korrelierten Pixel als Endmember auswählt [41].

• **Pixel Purity Index (PPI) [EEA]:** Ein Verfahren, das die spektrale Reinheit der Pixel bewertet und die reinsten Pixel als Endmember auswählt [42].

• **Fully Constrained Least Squares (FCLS) [Abundanz]:** Ein Verfahren das die Mischungsanteile durch die Minimierung der quadratischen Abweichung zwischen den Beobachtungen und der rekonstruierten linearen Mischung schätzt [43].

• **Least Absolute Shrinkage and Selection Operator (LASSO) [Abundanz]:** Ein Ansatz, der die L1-Norm-Regulierung verwendet, um eine spärliche Lösung für die Mischungsanteile zu erreichen. Dieser Ansatz kann Rauschen robust behandeln und die Anzahl der aktiven Mischungsanteile reduzieren [44].

• **Sparsity Promoting Iterated Constrained Endmember Algorithmus (SPICE) [EEA/Abundanz]:**

Der Kern von Sparse Unmixing-Ansätzen liegt in der Annahme, dass die spektralen Signaturen von Materialien in einem hyperspektralen Bild oft spärlich sind, d. h. die meisten Pixel sind nur aus einer kleinen Anzahl von Endmembern zusammengesetzt. Der SPICE-Algorithmus ist ein Vertreter dieser Ansätze, welcher in der Lage ist die Endmember und deren Anteile gleichzeitig zu schätzen. Er verwendet hierfür die Sparsity-Promoting-Regularisierung, die sicher stellt, dass nur wenige Endmember benötigt werden, um die spektrale Vielfalt im Bild effektiv abzudecken [45].

• Nicht-lineare Methoden:

• **Non-Negative Matrix Factorization (NMF) [EEA/Abundanz]:** Eine iterative Methode zur Schätzung der Endmember und ihrer Abundanz, bei der die hyperspektralen Daten als Produkt einer nichtnegativen Endmember-Matrix und einer nichtnegativen Proportions-Matrix modelliert werden. (Ref.: z. B. [46], [47])

• **Kernel-basierte Verfahren [Abundanz]:** Kernel-basierte Methoden bilden die Eingabedaten in einen höherdimensionalen Merkmalsraum ab, in dem eine nichtlineare Mischung durch ein lineares Modell angenähert wird (Ref.: z. B. [48])

• **Deep-Learning-basierte Verfahren [Abundanz]:** Deep-Learning-basierte Ansätze, wie z. B. das DSCN-Verfahren, nutzen häufig Convolutional Neural Networks (CNNs) oder auch Recurrent Neural Networks (RNNs), um komplexe nichtlineare Beziehungen zwischen den gemischten Pixelspektren und den entsprechenden Endmember-Spektren zu lernen. (Ref.: z. B. [49], [50])

• **Bayes'sche Unmixing Verfahren [EEA/Abundanz]:** Diese Algorithmen nutzen probabilistische Modelle zur Schätzung der Endmember und ihrer Abundanz. Bayes'sche Unmixing Verfahren basieren auf der Bayes'schen Statistik und ermöglichen die Berücksichtigung von a-priori Informationen und Unsicherheiten über die Endmember Verteilungen. Darüber hinaus ermöglichen diese Algorithmen eine robuste Schätzung der Endmember-Anteile, auch in Fällen mit geringer Datenqualität oder Störungen. (Ref.: z. B. [51])

Darüber hinaus gibt es eine Vielzahl weiterer Ansätze bzw. Modifikationen dieser Algorithmen für das spektrale Unmixing. Einen größeren Überblick zu den verwendeten Methoden liefert z. B. [52], [53], [54], [55] und [56]. Die Auswahl eines geeigneten Ansatzes ist letztlich immer von den spezifischen Anforderungen des Anwendungsfalls, den Eigenschaften der Daten und den verfügbaren Ressourcen abhängig. Eine Herausforderung ist beispielsweise immer die Wahl der angenommenen Anzahl von Endmembern die in einer Aufnahme vorkommen. Diese muss oft durch den Anwender auf Basis von Hintergrundinformationen und Erfahrungen initial abgeschätzt und gewählt werden. Jedoch gibt es auch Ansätze wie den SPICE-Algorithmus [45], welcher in der Lage ist, iterativ eine optimale Anzahl an Endmembern zu bestimmen, die die spektrale Vielfalt einer Aufnahme erklärt. Hinsichtlich der Wahl eines geeigneten Algorithmus für die EEA ist in jedem Fall noch zu berücksichtigen, dass einige Verfahren, wie beispielsweise VCA [40], PPI [42] oder N-FINDR [41] davon ausgehen, dass es mindestens ein „reines" Pixel je Endmember in der Aufnahme gibt, was nicht immer zutreffend ist.

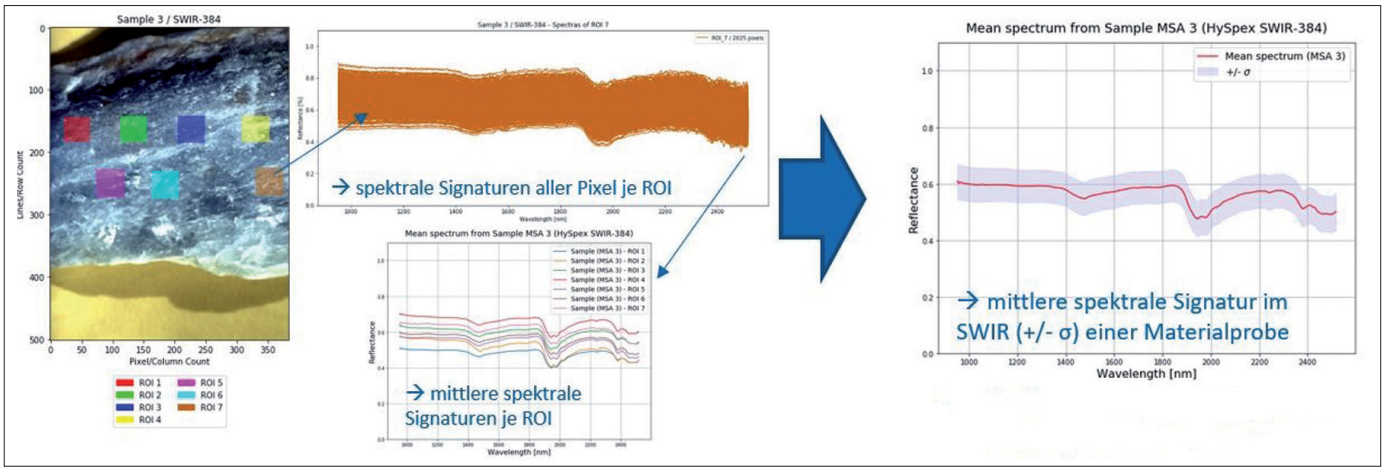

Abb. 6: Beispiel für die Ermittlung der mittleren spektralen Signatur einer Materialprobe mit Hilfe zufälliger ROIs

Eine Alternative, zur Zerlegung der Pixelspektren mit Hilfe des spektralen Unmixing, kann für verschiedene Anwendungen jedoch auch die Ermittlung einer mittleren spektralen Signatur für einen definierten Bildbereich sein, wie z. B. eine erfasste Gesteinsprobe. Diese Signaturen sind dann im besten Fall repräsentativ für einen bestimmten Objekttyp oder eine bestimmte Materialmischung. Für die Berechnung solcher mittleren spektralen Signaturen werden die Signaturen aller Pixel im definierten Bereich gemittelt bzw. es werden Strategien wie beispielsweise ein Random Sampling genutzt, wo nur eine bestimmte Anzahl zufällig ausgewählter Pixel gemittelt werden. Die Bachelorarbeit [57] widmet sich u. a. ausführlicher diesem Ansatz. In Abbildung 6 ist dieser Ansatz beispielhaft dargestellt, dabei wurden zufällig kleinere Regionen (ROIs) aus den interessierenden Bereichen einer Aufnahme selektiert und die Spektren der darin enthaltenen Pixel gemittelt. Anschließend wurden die mittleren Spektren aller ROIs nochmals gemittelt, um eine repräsentative mittlere spektrale Signatur der Materialprobe inkl. Standardabweichung zu erhalten.

2.3.2. Vergleich bzw. Identifikation von Spektren

Spektrale Signaturen, wie sie beispielsweise mit Methoden des spektralen Unmixing gewonnen werden, stellen im nächsten Schritt i. d. R. die Datenbasis für eine weiterführende Analyse bzw. einen Vergleich mit anderen Signaturen dar. Dabei können die Vergleichssignaturen ebenfalls, wie zuvor beschrieben, durch eigene Aufnahme und Analysen generiert werden oder aber auch aus so genannten Referenzbibliotheken stammen. Eine Referenzbibliothek ist eine Sammlung von hyperspektralen Signaturen bekannter Materialien. Diese Bibliotheken werden durch gezielte Feldmessungen, Laborexperimente oder Simulationen erstellt. Sie dienen als Grundlage für den Vergleich unbekannter Signaturen und ermöglichen die Identifizierung von Materialien anhand ihres spektralen Verhaltens. Die wohl bekanntesten frei verfügbaren Referenzbibliotheken sind die USGS Spectral Library (Version 7 [35]), sowie die ECOSTRESS Spectral Library (v1.0 [36]).

Die USGS Spectral Library ist eine umfangreiche Sammlung spektraler Signaturen von verschiedenen Materialien, die vom amerikanischen geologischen Dienst, United States Geological Survey (USGS) erstellt wurde. Sie dient als wichtige Referenzbibliothek für die Analyse und Interpretation von hyperspektralen Daten und wird von Wissenschaftlern, Forschern und Fachleuten weltweit genutzt. Die USGS Spectral Library in Version 7 [35] ist die aktuellste Version der Bibliothek und bietet verbesserte und erweiterte Daten im Vergleich zu den vorherigen Versionen. Sie enthält über 2.500 spektrale Signaturen von mehr als 800 Materialien, darunter Mineralien, Gesteine, Bodentypen, Vegetationstypen, Wasser und verschiedene anthropogene Materialien. Die spektralen Signaturen wurden durch Messungen und Analysen in Laboren und Feldstudien generiert. Sie decken einen breiten spektralen Bereich ab, der vom ultravioletten (0.35 µm) bis zum kurzwelligen Infrarot (SWIR) (2.5 µm) reicht und wichtige Informationen über die spektralen Eigenschaften der Materialien liefert. Jede Signatur in der Bibliothek ist darüber hinaus mit detaillierten Metadaten versehen, die Informationen über das Material, die Messbedingungen und andere relevante Daten enthalten. Die Referenzbibliothek steht der wissenschaftlichen Gemeinschaft kostenfrei zur Verfügung und kann über die offizielle Website des USGS (https://crustal.usgs.gov/speclab/QueryAll07a.php) heruntergeladen werden. Durch ihre umfassende Abdeckung und ihre hochwertigen Daten ist sie ein wertvolles Werkzeug für die Forschung und Anwendung hyperspektraler Technologien und trägt zur Weiterentwicklung des Verständnisses und der Nutzung spektraler Signaturen bei.

Die ECOSTRESS Spectral Library v1.0 [36] ist eine spezielle Referenzbibliothek, die von der NASA entwickelt wurde und insbesondere für die Analyse von Pflanzenspektren und deren Wärmesignaturen konzipiert wurde. ECOSTRESS steht für „Ecosystem Spaceborne Thermal Radiometer Experiment on Space Station“ und ist ein Instrument an Bord der Internationalen Raumstation, dass die Wärmeabstrahlung der Erdoberfläche aus dem Weltraum misst. Die Bibliothek enthält eine vielfältige Sammlung von spektralen Signaturen verschiedener Pflanzenarten und Vegetationstypen, sowie darüber hinaus auch von Mineralien, Gesteinen und anthropogenen Strukturen. Dies ermöglicht eine umfassende Analyse von Ökosystemen und insbesondere Analysen von Phänomenen wie Pflanzengesundheit, Stressreaktionen auf Umweltbedingungen, Transpiration und Verdunstungsraten und trägt zur weiteren Erforschung der Wechselwirkungen zwischen Pflanzen, Umwelt und menschlichen Aktivitäten bei. Die enthaltenen Signaturen wurden im Wellenlängenbereich vom ultravioletten bis in den thermischen Bereich durch umfangreiche Feldmessungen und Untersuchungen in verschiedenen Ökosystemen weltweit erfasst. Die Bibliothek (http://speclib.jpl.nasa.gov) ist öffentlich verfügbar und ein wertvolles Werkzeug zur Förderung des Verständnisses von Ökosystemen, insbesondere im Zusammenhang mit Wasserverfügbarkeit und Klimaveränderungen.

Es existieren nun verschiedene Methoden zum Vergleich von einzelnen spektralen Signaturen, unabhängig davon wie diese ermittelt wurden. Populäre Methoden sind u. a. das sogenannte Continuum Removal [58], die Kreuzkorrelation oder die spektrale Winkelmethode (Spectral Angle Mapper (SAM) [59]). Diese Methoden sollen nachfolgend nun kurz vorgestellt werden.

Beim Continuum Removal [58] werden kontinuierliche spektrale Informationen aus den gemessenen Spektren entfernt, um nur die diskreten Absorptionsmerkmale eines Materials zu betrachten. Das Verfahren ermöglicht damit eine verbesserte Identifikation und Vergleichbarkeit von spektralen Signaturen bzw. der charakteristischen Merkmale in diesen. Im Detail beinhaltet das Verfahren folgende Schritte:

1. Erfassung / Modellierung des Kontinuums: Das Kontinuum wird zunächst anhand der spektralen Signatur modelliert bzw. geschätzt. Dies kann durch verschiedene Ansätze erfolgen, wie beispielsweise Polynominterpolation, lineare Regression, statistische Methoden oder geometrische Methoden.

2. Subtraktion des Kontinuums: Das modellierte Kontinuum wird von den ursprünglichen spektralen Daten abgezogen.

3. Interpretation der bereinigten Daten: Nach der Durchführung des Continuum Removal werden die bereinigten spektralen Daten analysiert, um die spezifischen Merkmale oder Signaturen zu identifizieren und zu interpretieren, die zuvor vom Kontinuum überlagert wurden. Der Vergleich, der um das Kontinuum reduzierten Signaturen, konzentriert sich dann auf spezifische Absorptionsmerkmale, die charakteristisch für das untersuchte Material sind. Dies kann die Detektion von Materialien, die Charakterisierung von Eigenschaften oder die Erkennung von Veränderungen erleichtern.

Durch das Entfernen des Kontinuums können also atmosphärische und instrumenten- bzw. aufnahmebedingte Effekte eliminiert werden, die das spektrale Signal überlagern oder verdecken, was die Interpretation der Daten erschwert. Die Abbildung 7 zeigt beispielhaft die Anwendung des Verfahrens. Als Methode für die Modellierung des Kontinuums wurde in diesem Beispiel der geometrische Ansatz der konvexen Hülle, als kleinste konvexe geometrische Figur die alle Punkte einer gegebenen Datenmenge einschließt, verwendet.

Eine Kreuzkorrelationsanalyse ermöglicht die quantitative Bewertung der Ähnlichkeit zwischen zwei Spektren, indem sie die Übereinstimmung ihrer Form und Muster analysiert. Um die Kreuzkorrelation für den Vergleich von Spektren zu nutzen, werden die beiden Spektren als Signale betrachtet. Die Kreuzkorrelation berechnet dann die Ähnlichkeit zwischen diesen beiden Signalen, indem sie die Verschiebung (Lag) eines Signals relativ zum anderen berücksichtigt. Die Kreuzkorrelation wird durch die Faltung der beiden zentrierten Signale berechnet. Dieser Schritt beinhaltet die schrittweise Verschiebung (Lag) eines Signals entlang der x-Achse und die Multiplikation der Werte der beiden Signale bei jeder Verschiebung. Das Ergebnis ist eine Kreuzkorrelationsfunktion, die den Ähnlichkeitsgrad zwischen den Spektren als Funktion der Verschiebung darstellt. Diese Kreuzkorrelationsfunktion wird anschließend analysiert. Der höchste Wert der Funktion, der sogenannte Peak, zeigt die maximale Übereinstimmung zwischen den Spektren und gibt Auskunft über den Grad der Ähnlichkeit. Die Position des Peaks gibt die Lag-Verschiebung an, bei der die maximale Ähnlichkeit auftritt. Ein hoher Peak-Wert und eine geringe Lag-Verschiebung deuten letztlich auf eine hohe Ähnlichkeit hin. Die Kreuzkorrelation reagiert empfindlich auf Verschiebungen und Änderungen in den spektralen Mustern, aber weniger auf Unterschiede in der Intensität oder Skalierung der Spektren.

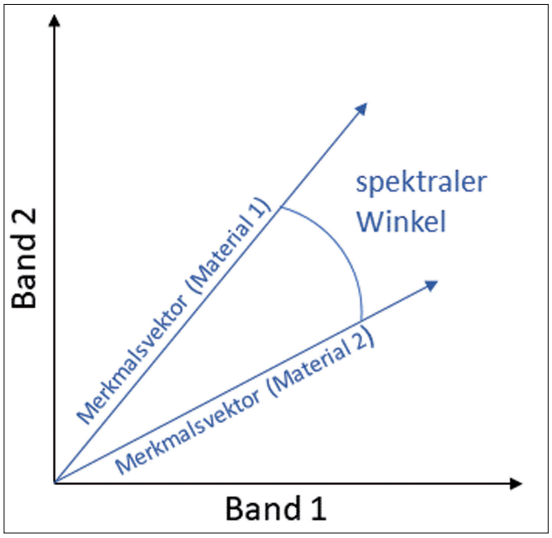

Abb. 8: Konzept des Spectral Angle Mapper (SAM)

Das Spectral Angle Mapper Verfahren (SAM) [59] ist eine Methode für den Vergleich spektraler Signaturen, welche auch für die überwachte Klassifikation von hyperspektralen Aufnahmen oder das Target Detection verwendet wird (s. Abschnitt 2.3.3). Die Methode basiert auf dem Konzept des spektralen Winkels zwischen zwei Signaturen und zielt darauf ab, Ähnlichkeiten oder Unterschiede in ihren spektralen Eigenschaften zu quantifizieren. Dafür werden die spektralen Signaturen als Vektoren im hyperspektralen Merkmalsraum betrachtet und der

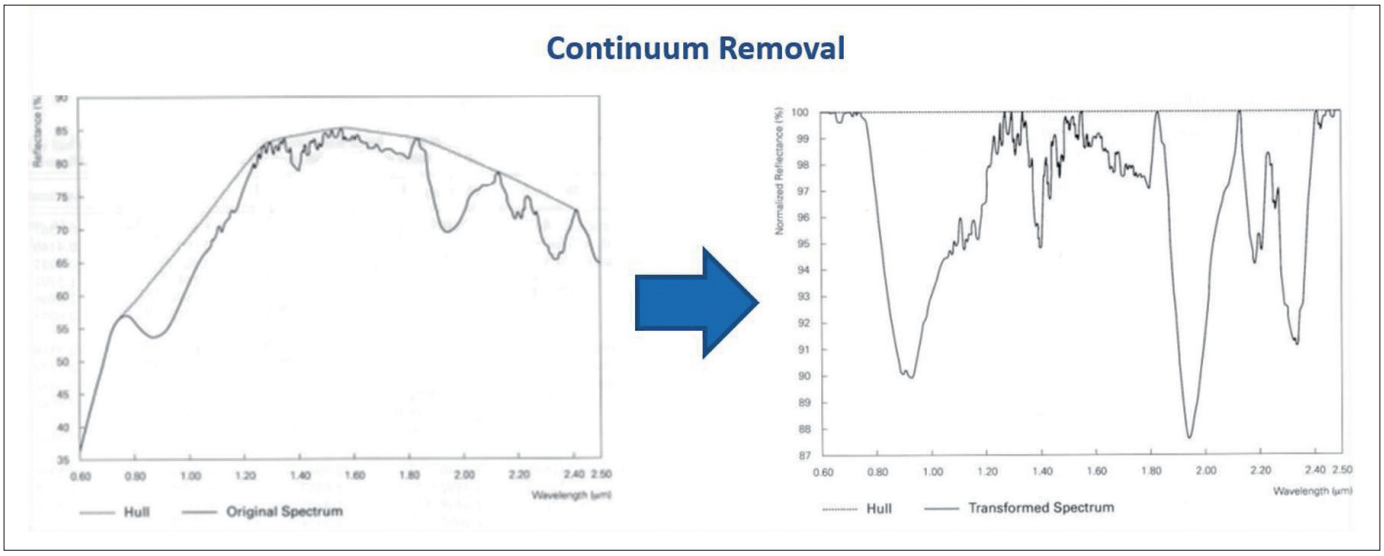

Abb. 7: Anwendung des Continuum Removal Verfahrens für die verbesserte Identifikation und Vergleichbarkeit von spektralen Signaturen und ihren charakteristischen Merkmalen

spektrale Winkel zwischen den Signaturen wird dann als Maß für die Ähnlichkeit der Signaturen verwendet (s. Abbildung 8). Ein kleiner spektraler Winkel zwischen zwei Signaturen deutet auf eine hohe Ähnlichkeit hin, während ein großer Winkel auf deutliche Unterschiede hinweist. Die spektrale Winkelmethode ermöglicht somit eine einfache und schnelle Bewertung der Ähnlichkeit zwischen Signaturen, ohne dass eine umfassende Kenntnis über die spektralen Eigenschaften der Materialien erforderlich ist. Wie auch die Kreuzkorrelation reagiert die SAM-Methode empfindlich auf Unterschiede in den spektralen Mustern, aber weniger auf Unterschiede in der Intensität der Signaturen.

2.3.3. Klassifikation und Target Detection

Im vorangegangenen Abschnitt wurden Methoden zum Vergleich einzelner spektraler Signaturen, die aus hyperspektralen Aufnahmen ermittelt wurden, vorgestellt. Ein anderer Ansatz ist es alle Pixel einer erfassten hyperspektralen Aufnahme zu klassifizieren, d. h. jedem Pixel ein Label (Klasse) zu zuordnen. Dabei können sowohl überwachte als auch unüberwachte Klassifikationsverfahren eingesetzt werden.

Bei überwachten Klassifikationsverfahren wird ein Trainingsdatensatz verwendet, der bereits klassifizierte Pixel enthält. Anhand dieser Beispiele lernt ein Algorithmus, Muster und Merkmale zu erkennen, um neue, unbekannte Pixel in die entsprechenden Klassen einzuteilen. Typischerweise werden Verfahren (Klassifikatoren) wie die Support Vector Machine (SVM) [60], Maximum Likelihood Classifier (MLC) [61], Random Forest Classifier (RFC) oder künstliche neuronale Netze (z. B. CNNs) [62] für die überwachte Klassifikation eingesetzt. Durch die Verwendung von spektralen Signaturen als Trainingsdaten, die charakteristisch für bestimmte Materialien oder Objekte sind, können diese Verfahren die räumliche Verteilung von Materialien bzw. Objekten in einer hyperspektralen Aufnahme kartieren.

Im Gegensatz dazu basieren unüberwachte Klassifikationsverfahren auf statistischen Methoden und Clustering-Algorithmen, um natürliche Gruppierungen in den spektralen Daten zu identifizieren. Diese Ansätze erfordern keinen vorgegebenen Trainingsdatensatz, sondern sind rein datengetrieben und können somit für die Entdeckung unbekannter Klassen oder Anomalien in den Daten verwendet werden. Beispiele für unüberwachte Klassifikationsverfahren sind das k-Means oder Isodata Verfahren. Im Unterschied zu den überwachten Verfahren erfolgt die Zuweisung z. B. einer mineralogischen Bedeutung der Klassen, erst im anschließenden Post-Processing. Die Abbildung 9 zeigt beispielhaft die unüberwachte Klassifikation eines definierten Bereichs (rot) einer aufgenommenen Gesteinsprobe. Wie bereits erwähnt erfolgt die Zuordnung einer Klassenbedeutung für die 5 Cluster erst im nach hinein durch den Anwender.

Die Erkennung bestimmter Ziel-Signaturen, die so genannte Target Detection, ist in gewisser Weise eine spezielle Variante der überwachten Klassifikation, bei der es nicht um die Klassifikation der kompletten hyperspektralen Aufnahme geht, sondern vielmehr um die Identifikation spezifischer Ziele oder Objekte in gegebenen Aufnahmen. Ziel ist also die automatisierte Erkennung von spezifischen Merkmalen in großen Datensätzen, da diese für eine manuelle Analyse i. d. R. schlichtweg zu umfangreich sind. Zielobjekte können dabei beispielsweise Schadstoffe, Pflanzenkrankheiten oder Mineralvorkommen sein, welche durch eine eindeutige spektrale Charakteristik beschrieben werden können. Grundsätzlich können alle algorithmischen Ansätze der überwachten Klassifikation auch für die Target Detection genutzt werden. Einen Überblick zu algorithmischen Ansätzen und Herausforderungen der Target Detection werden beispielsweise in [63] und [64] gegeben.

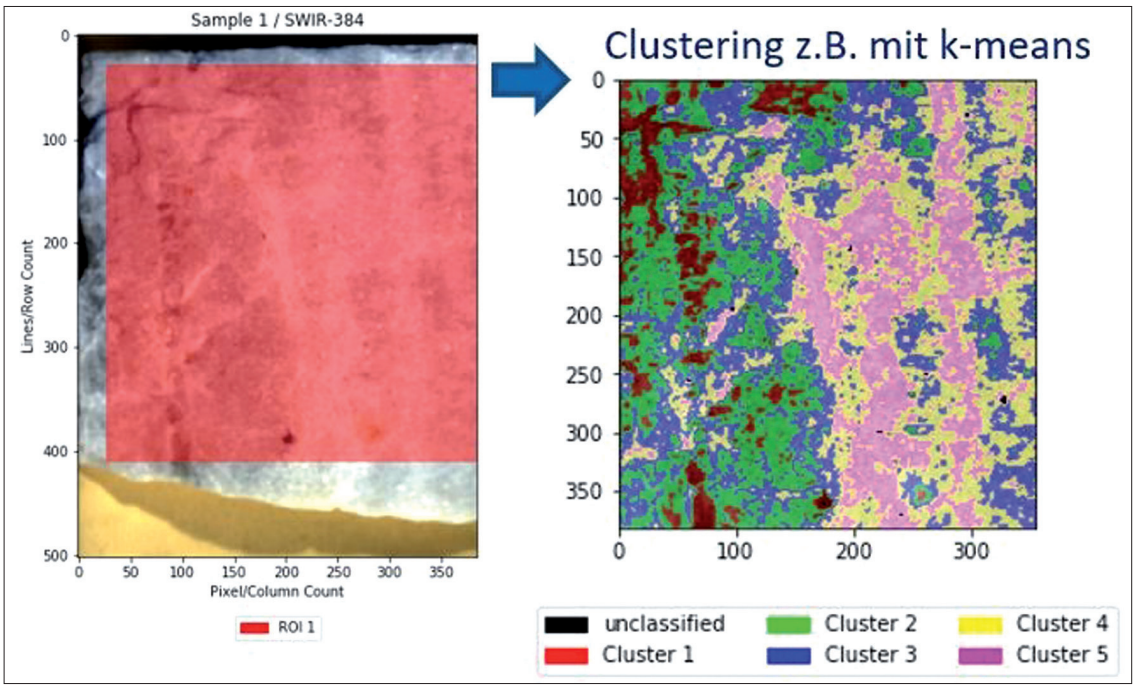

Abb. 9: Beispiel einer unüberwachten Klassifikation eines hyperspektralen Datensatzes

Ausblick

Im kommenden Teil 2 des Beitrages sollen ausgesuchte Techniken bzw. Algorithmen der Datenerfassung, Datenvorverarbeitung und Datenanalyse anhand von Anwendungsbeispielen und Fallstudien vorgestellt werden.

Referenzen

1. P. O. Noack, „Einsatz von Multi- und Hyperspektralsensoren in der Landwirtschaft," in 38. Wissenschaftlich-Technische Jahrestagung der DGPF und PFGK18 Tagung in München – Publikationen der DGPF, Band 27, 2018.
2. J. Ma, D.-W. Sun, H. Pu, J.-H. Cheng und Q. Wei, „Advanced Techniques for Hyperspectral Imaging in the Food Industry: Principles and Recent Applications," Annual Review of Food Science and Technology, Bd. 10, pp. 197-220, 2019.
3. B. Park und R. Lu, Hyperspectral imaging technology in food and agriculture, Bd. 1, Springer, 2015.
4. S. Serranti, „Plastic waste monitoring and recycling by hyperspectral imaging technology," in SPIE Future Sensing Technologies, 2019.
5. G. Bonifazi und S. Serranti, „Quality control by Hyper-Spectral Imaging (HSI) in solid waste recycling: logics, algorithms and procedures," in Image Processing: Machine Vision Applications VII, 2014.
6. G. Lu and B. Fei, "Medical hyperspectral imaging: a review.," Journal of biomedical optics, vol. 19, no. 1, p. 10901, January 2014.
7. J. Yoon, „Hyperspectral Imaging for Clinical Applications," BioChip Journal, Bd. 16, p. 1–12, 2022.
8. R. B. Gomez und S. Dasgupta, „Use of hyperspectral remote sensing for detection and monitoring of chemical and biological agents: a survey," in Chemical and Biological Standoff Detection II, 2004.
9. K. Ruxton, G. Robertson, B. Miller, G. P. A. Malcolm und G. T. Maker, „Hazardous material analysis using mid-wave infrared hyperspectral imaging techniques," in Chemical, Biological, Radiological, Nuclear, and Explosives (CBRNE) Sensing XIV, 2013.
10. H. Bürsing und W. Gross, „Hyperspectral imaging: future applications in security systems," Advanced Optical Technologies, Bd. 6, p. 61–66, 2017.
11. M. Pallocci, M. Treglia, P. Passalacqua, L. D. Luca, C. Zanovello, D. Mazzuca, F. Guarna, S. Gratteri und L. T. Marsella, „Forensic applications of hyperspectral imaging technique: a narrative review," Medico-Legal Journal, Bd. 90, pp. 216-220, 2022.
12. K. de Cássia Mariotti, R. S. Ortiz und M. F. Ferrão, „Hyperspectral imaging in forensic science: An overview of major application areas," Science & Justice, Bd. 63, pp. 387-395, 2023.
13. S. Peyghambari und Y. Zhang, „Hyperspectral remote sensing in lithological mapping, mineral exploration, and environmental geology: an updated review," Journal of Applied Remote Sensing, Bd. 15, p. 031501, 2021.
14. E. Bedini, „The use of hyperspectral remote sensing for mineral exploration: a review," Journal of Hyperspectral Remote Sensing, Bd. 7, p. 189, December 2017.
15. A. Beiranvand Pour und M. Hashim, „ASTER, ALI and Hyperion sensors data for lithological mapping and ore minerals exploration," SpringerPlus, Bd. 3, p. 130, 2014.
16. F. Koerting, C. Rogass, H. Kaempf, C. Lubitz, U. Harms, M. Schudack, R. Kokaly, C. Mielke, N. Boesche und U. Altenberger, „DRILL CORE MINERAL ANALYSIS BY MEANS OF THE HYPERSPECTRAL IMAGING SPECTROMETER HySpex, XRD AND ASD IN PROXIMITY OF THE MÝTINA MAAR, CZECH REPUBLIC," ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Bde. %1 von %2XL-1/W5, p. 417–424, 2015.
17. S. T. Thiele, S. Lorenz, M. Kirsch, I. C. C. Acosta, L. Tusa, E. Herrmann, R. Möckel und R. Gloaguen, „Multi-scale, multi-sensor data integration for automated 3-D geological mapping," Ore Geology Reviews, Bd. 136, p. 104252, 2021.
18. S. Sudharsan, R. Hemalatha und S. Radha, „A Survey on Hyperspectral Imaging for Mineral Exploration using Machine Learning Algorithms," in 2019 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET), 2019.
19. P. Bierwirth, D. P. Huston und R. Blewett, „Hyperspectral Mapping of Mineral Assemblages Associated with Gold Mineralization in the Central Pilbara, Western Australia," Economic Geology: Bulletin of the Society of Economic Geologists, Bd. 97, pp. 819-826, 2002.
20. N. Lin, H. Liu, G. Li, M. Wu, D. Li, R. Jiang und X. Yang, „Extraction of mineralized indicator minerals using ensemble learning model optimized by SSA based on hyperspectral image," Open Geosciences, Bd. 14, p. 1444–1465, 2022.
21. M. Mbuh, „Use of Hyperspectral Remote Sensing to Estimate Water Quality," in Processing and Analysis of Hyperspectral Data, J. Chen, Y. Song und H. Li, Hrsg., Rijeka, IntechOpen, 2019.
22. C. Goyens, H. Lavigne, A. Dille und H. Vervaeren, „Using Hyperspectral Remote Sensing to Monitor Water Quality in Drinking Water Reservoirs," Remote Sensing, Bd. 14, 2022.
23. M. Govender, K. Chetty und H. Bulcock, „A review of hyperspectral remote sensing and its application in vegetation and water resource studies," Water SA, Bd. 33, pp. 145-151, 2007.
24. J. Im und J. R. Jensen, „Hyperspectral Remote Sensing of Vegetation," Geography Compass, Bd. 2, pp. 1943-1961, 2008.
25. P. S. Thenkabail, M. K. Gumma, P. Teluguntla und A. M. Irshad, „Hyperspectral remote sensing of vegetation and agricultural crops," Photogrammetric Engineering & Remote Sensing (TSI), Bd. 80, p. 695–723, 2014.
26. V. Singh, „Application of Hyperspectral Remote Sensing in Forest Health Assessment and Mapping," 2018.
27. G. Sun, Z. Jiao, A. Zhang, F. Li, H. Fu und Z. Li, „Hyperspectral image-based vegetation index (HSVI): A new vegetation index for urban ecological research," International Journal of Applied Earth Observation and Geoinformation, Bd. 103, p. 102529, 2021.
28. F. Salem, M. Kafatos, T. El-Ghazawi, R. Gomez und R. Yang, „Hyperspectral image analysis for oil spill detection," in Summaries of NASA/JPL Airborne Earth Science Workshop, Pasadena, CA, 2001.
29. B. B. G.Andreoli und D. T. B.Hosgood, „Hyperspectral Analysis of Oil and Oil-Impacted Soilsfor Remote Sensing Purposes," 2007.
30. P. Souto-Ceccon, G. Simarro, P. Ciavola, A. Taramelli und C. Armaroli, „Shoreline Detection from PRISMA Hyperspectral Remotely-Sensed Images," Remote Sensing, Bd. 15, 2023.
31. M. L. McIntyre, D. F. Naar, K. L. Carder, B. T. Donahue und D. J. Mallinson, „Coastal Bathymetry from Hyperspectral Remote Sensing Data: Comparisons with High Resolution Multibeam Bathymetry," Marine Geophysical Researches, Bd. 27, p. 129–136, 2006.
32. B. Zhang, D. Wu, L. Zhang, Q. Jiao und Q. Li, „Application of hyperspectral remote sensing for environment monitoring in mining areas," Environmental Earth Sciences, Bd. 65, p. 649–658, 2012.
33. C. Ong, „Mapping and Monitoring The Environmental Impacts Of Mining Using Hyperspectral Data," 2014.
34. H. Flores, S. Lorenz, R. Jackisch, L. Tusa, I. C. Contreras, R. Zimmermann und R. Gloaguen, „UAS-Based Hyperspectral Environmental Monitoring of Acid Mine Drainage Affected Waters," Minerals, Bd. 11, 2021.
35. U. S. G. Survey, R. F. Kokaly, R. N. Clark, G. A. Swayze, K. E. Livo, T. M. Hoefen, N. C. Pearson, R. A. Wise, W. M. Benzel, H. A. Lowers, R. L. Driscoll and A. J. Klein, "USGS Spectral Library Version 7," Reston, 2017.

36. S. K. Meerdink, S. J. Hook, D. A. Roberts und E. A. Abbott, „The ECOSTRESS spectral library version 1.0," Remote Sensing of Environment, Bd. 230, p. 111196, 2019.
37. Y. W. Wang, N. P. Reder, S. Kang, A. K. Glaser und J. T. C. Liu, „Multiplexed Optical Imaging of Tumor-Directed Nanoparticles: A Review of Imaging Systems and Approaches," Nanotheranostics, Bd. 1, pp. 369-388, 2017.
38. B. Kumar, O. Dikshit, A. Gupta und M. Singh, „Feature extraction for hyperspectral image classification: a review," International Journal of Remote Sensing, Bd. 41, pp. 6248-6287, June 2020.
39. B. Rasti, D. Hong, R. Hang, P. Ghamisi, X. Kang, J. Chanussot und J. A. Benediktsson, „Feature Extraction for Hyperspectral Imagery: The Evolution From Shallow to Deep: Overview and Toolbox," IEEE Geoscience and Remote Sensing Magazine, Bd. 8, p. 60–88, December 2020.
40. J. M. P. Nascimento und J. M. B. Dias, „Vertex component analysis: a fast algorithm to unmix hyperspectral data," IEEE Transactions on Geoscience and Remote Sensing, Bd. 43, pp. 898-910, April 2005.
41. M. E. Winter, „N-FINDR: an algorithm for fast autonomous spectral end-member determination in hyperspectral data," in Imaging Spectrometry V, 1999.
42. J. Boardman, F. Kruscl und R. Grccn, „Mapping target signatures via partial unmixing of AVIRIS data," Summaries of the Fifth Annual JPL Airborne Earth Science Workshop, January 1995.
43. D. C. Heinz und C. I-Chang, „Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery," IEEE Transactions on Geoscience and Remote Sensing, Bd. 39, pp. 529-545, March 2001.
44. D. V. Samarov, M. Clarke, J. Y. Lee, D. Allen, M. Litorja und J. Hwang, „Validating the LASSO algorithm by unmixing spectral signatures in multicolor phantoms," in Optical Diagnostics and Sensing XII: Toward Point-of-Care Diagnostics; and Design and Performance Validation of Phantoms Used in Conjunction with Optical Measurement of Tissue IV, 2012.
45. A. Zare und P. Gader, „Sparsity Promoting Iterated Constrained Endmember Detection in Hyperspectral Imagery," IEEE Geoscience and Remote Sensing Letters, Bd. 4, pp. 446-450, 2007.
46. R. Zdunek, „Hyperspectral image unmixing with Nonnegative Matrix Factorization," in 2012 International Conference on Signals and Electronic Systems (ICSES), 2012.
47. X.-R. Feng, H.-C. Li, R. Wang, Q. Du, X. Jia und A. Plaza, Hyperspectral Unmixing Based on Nonnegative Matrix Factorization: A Comprehensive Review, 2022.
48. J. Broadwater, A. Banerjee und P. Burlina, „Kernel Methods for Unmixing Hyperspectral Imagery," Kernel Methods for Remote Sensing Data Analysis, pp. 247-269, November 2009.
49. S. Jonglr, „DEEP LEARNING IN HYPERSPECTRAL UNMIXING: A REVIEW," September 2020.
50. D. Hong, L. Gao, J. Yao, N. Yokoya, J. Chanussot, U. Heiden und B. Zhang, „Endmember-Guided Unmixing Network (EGU-Net): A General Deep Learning Framework for Self-Supervised Hyperspectral Unmixing," IEEE Transactions on Neural Networks and Learning Systems, Bd. 33, pp. 6518-6531, 2022.
51. J. Hahn und A. M. Zoubir, Bayesian Nonparametric Unmixing of Hyperspectral Images, 2017.
52. M. A. Veganzones und M. Graña, „Endmember Extraction Methods: A Short Review," in KES, 2008.
53. J. M. Bioucas-Dias, A. Plaza, N. Dobigeon, M. Parente, Q. Du, P. Gader und J. Chanussot, „Hyperspectral Unmixing Overview: Geometrical, Statistical, and Sparse Regression-Based Approaches," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Bd. 5, pp. 354-379, 2012.
54. R. Heylen, M. Parente und P. Gader, „A Review of Nonlinear Hyperspectral Unmixing Methods," Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of, Bd. 7, pp. 1844-1868, June 2014.
55. N. Dobigeon, J.-Y. Tourneret, C. Richard, J. C. M. Bermudez, S. McLaughlin und A. O. Hero, „Nonlinear Unmixing of Hyperspectral Images: Models and Algorithms," IEEE Signal Processing Magazine, Bd. 31, pp. 82-94, 2014.
56. R. Zdunek, J. Wei und X. Wang, „An Overview on Linear Unmixing of Hyperspectral Data," Mathematical Problems in Engineering, Bd. 2020, p. 3735403, 2020.
57. F. R. Matzke, Erarbeitung eines Workflows zur hyperspektralen Materialcharakterisierung im Labor, 2021.
58. R. N. Clark und T. L. Roush, „Reflectance spectroscopy: Quantitative analysis techniques for remote sensing applications," Journal of Geophysical Research: Solid Earth, Bd. 89, pp. 6329-6340, 1984.
59. R. H. Yuhas, A. F. H. Goetz und J. W. Boardman, „Discrimination among semi-arid landscape endmembers using the spectral angle mapper (SAM) algorithm," in JPL, Summaries of the Third Annual JPL Airborne Geoscience Workshop. Volume 1: AVIRIS Workshop, 1992.
60. C. Cortes und V. Vapnik, „Support-vector networks," Machine Learning, Bd. 20, p. 273–297, 1995.
61. P. S. Sisodia, V. Tiwari und A. Kumar, „Analysis of Supervised Maximum Likelihood Classification for remote sensing image," in International Conference on Recent Advances and Innovations in Engineering (ICRAIE-2014), 2014.
62. P. Zhang, „Neural Networks for Classification: A Survey," Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on, Bd. 30, pp. 451-462, December 2000.
63. Sneha und A. Kaul, „Hyperspectral imaging and target detection algorithms: a review," Multimedia Tools and Applications, Bd. 81, p. 44141–44206, 2022.
64. N. M. Nasrabadi, „Hyperspectral Target Detection: An Overview of Current and Future Challenges," IEEE Signal Processing Magazine, Bd. 31, pp. 34-44, January 2014.