
Online Beleuchtungsausgleich für terrestrische Hyperspektralaufnahmen

Thomas WIEMANN, Alexander DITT, Felix IGELBRINK, Joachim HERTZBERG

Zusammenfassung

Bei der Aufnahme von 3D-Laserscans können verschiedene Arten von Kameras eingesetzt werden, um die aufgenommenen Punkte mit weiteren Informationen zu annotieren. In diesem Beitrag stellen wir ein System vor, das als zusätzlichen Sensor eine Hyperspektralkamera verwendet. Diese ermöglicht die Erfassung eines großen Bereichs des Lichtspektrums und gibt somit detaillierten Aufschluss über das Reflektionsverhalten unterschiedlicher Materialien. Beim terrestrischen Scannen mit einer solchen Kamera ergeben sich allerdings zeitlich bedingte Beleuchtungsunterschiede. Insbesondere durch die Änderung des Kamerawinkels relativ zur Sonne sowie lokale Verhältnisse treten pro Scanposition starke Änderungen der Intensitätswerte innerhalb der aufgenommenen Hyperspektralbilder auf. Dieser Beitrag zeigt die zu erwartenden Probleme beim Einsatz eines solchen Systems auf und zeigt erste Ansätze zur Kompensation der auftretenden Intensitätsschwankungen.

1 Motivation

Klassifikation von Materialien basierend auf ihren spektralen Signaturen wird seit dem Start der Landsat-Satelliten in den später 1970er und frühen 1980er im Bereich der Fernerkundung erfolgreich durchgeführt. Basierend auf den aufgenommenen Satellitenbildern wurden verschiedene Verfahren entwickelt, die es erlauben, mit Hilfe von Multispektralkameras Oberflächen automatisch zu klassifizieren (MATHER & TSO 2016). Bei satellitengestützten Aufnahmen stehen üblicherweise nur einige wenige ausgewählte Spektralkanäle zur Verfügung. Heutzutage kommen in der Fernerkundung neben Satellitenbildern zunehmend Drohnen zum Einsatz, die mit ähnlichen Kameras ausgerüstet werden können. Die technische Entwicklung erlaubt es zudem auch immer mehr Spektralkanäle aufzunehmen. Somit können wesentlich besser aufgelöste spektrale Signaturen aufgenommen werden, die es erlauben, weitaus mehr Materialien zu klassifizieren, als dies mit Multispektralkameras möglich ist (GOVENDER ET AL. 2008). Satelliten- und drohnengestützten Aufnahmen ist gemein, dass sie aus relativ großer Höhe aufgenommen werden und daher unter einem relativ steilen Winkel auf die zu betrachtende Oberfläche blicken, weshalb innerhalb einzelner Aufnahmen nur verhältnismäßig wenig blickwinkelabhängige Intensitätsschwankungen auftreten.

In IGELBRINK ET AL. (2018) wurde ein Verfahren vorgestellt, welches es erlaubt, eine Hyperspektralkamera mit einem markerlosen Verfahren automatisch gegen einen terrestrischen Laserscanner zu kalibrieren. Beim Scannen erzeugt dieses System automatisch aus den Daten der Hyperspektralkamera ein Panorama, mit dessen Hilfe die aufgenommenen 3D-Punkte hyperspektral annotiert werden können. Dabei hat sich gezeigt, dass bei der Aufnahme mit einem solchen Setup die aufgenommenen Intensitäten sehr richtungsabhängig sind und stark von den Umgebungsbedingungen abhängen. So macht es einen großen Unterschied, ob aus einem schattigen Bereich

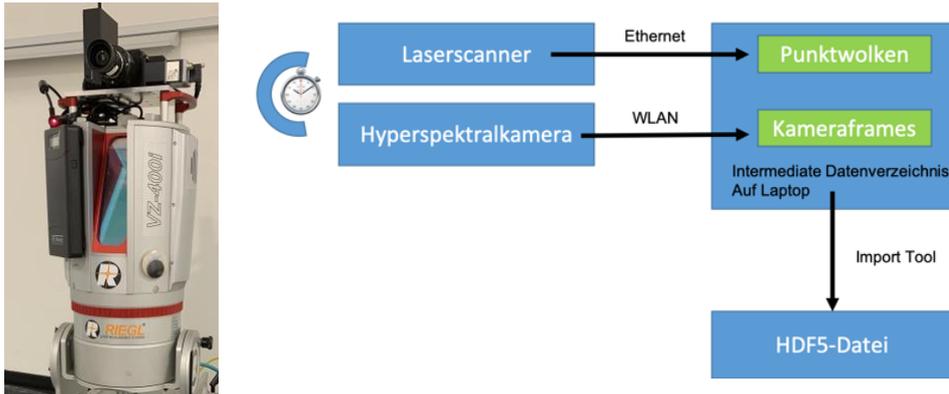


Abb. 1: Aufbau des Scanning-Systems bestehend aus Riegl VZ400i Laserscanner, Resonon Pika-L Hyperspektralkamera sowie externem Akku und dediziertem Mini-PC (links) sowie schematische Darstellung der Datensynchronisation.

heraus gescannt wird oder an sonnigen Positionen Daten aufgenommen werden. Neben diesen Faktoren spielt auch die Tatsache, dass die Kamera zusammen mit dem Scanner rotiert, eine entscheidende Rolle: einmal pro Scan schaut die Kamera direkt in Richtung der Sonne beziehungsweise von ihr weg. Diese inhärenten Beleuchtungsschwankungen erschweren es, die bekannten Verfahren aus der Fernerkundung auf die so aufgenommenen Daten zu übertragen. In diesem Beitrag schildern wir erste Ansätze und Ideen zur Normalisierung der aufgenommenen Daten.

Im Folgenden beschreiben wir zunächst den Aufbau unseres Scanning-Systems. Anschließend zeigen wir anhand eines Beispiels die Probleme auf, die sich bei der Klassifikation mit Standardverfahren auf diesen Daten ergeben, und wie die Ergebnisse mit Hilfe von Offline-Verfahren verbessert werden können. Darauf aufbauend motivieren wir die Entwicklung eines Verfahrens zum Online-Beleuchtungsausgleich und präsentieren erste Ansätze, die sich derzeit in der Entwicklung befinden.

2 Aufbau des terrestrischen Scanning-Systems

Das Scanning-System zur Aufnahme von hyperspektralen 3D-Punktwolken ist in Abb. 1 dargestellt. Die Basis bildet ein Riegl VZ400i Scanner, auf dem eine Resonon Pika-L Hyperspektralkamera befestigt wurde. Diese Zeilenkamera rotiert mit dem Laserscanner und erzeugt dabei ein 360°-Panoramabild. Die Ansteuerung des Systems erfolgt über einen Laptop, auf dem die Daten der beiden Sensoren mit Hilfe einer selbst entwickelten Software synchronisiert werden. Die Ansteuerung des Laserscanners erfolgt dabei über die von Riegl bereitgestellte RivLib. Die Hyperspektralkamera auf dem Scanner wird an einen NanoPC-T4 mit 4GB RAM und 5Ghz Wifi angesteuert. Dies ist nötig, da der Scanner im vorliegenden Setup keine USB3-Schnittstelle zur Verfügung stellt, die zur Ansteuerung der Kamera benötigt wird. Die Hyperspektralkamera nutzt intern einen Chip der Firma Basler. Die Frames werden daher auf dem NanoPC mit dem frei verfügbaren Pylon-Treiber abgegriffen und von einem

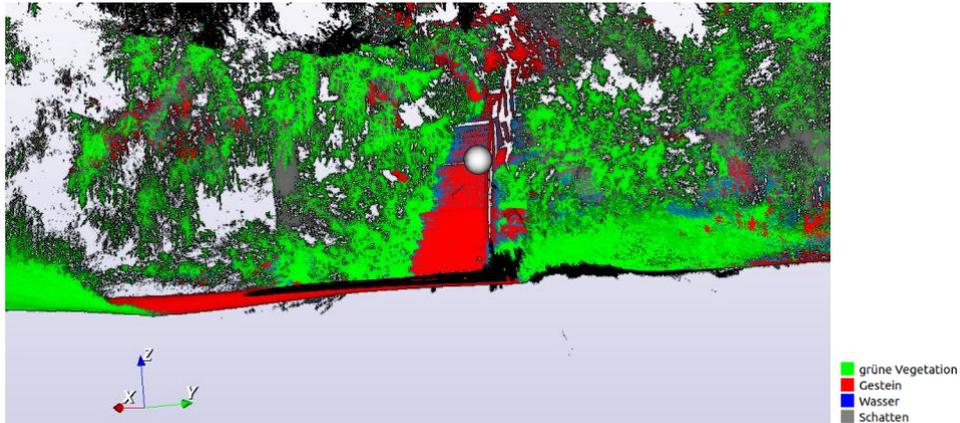


Abb. 2: Klassifikation einer hyperspektralen Punktwolke mittels eines gelernten Random-Forest-Klassifikators. Die Abbildung zeigt eine Szene aus dem Referenzdatensatz des Botanischen Gartens der Universität Osnabrück¹.

Service, der automatisch mit dem NanoPC gestartet wird, mit Zeitstempel versehen via ZeroMQ an den Steuerungslaptop gesendet. Damit keine Daten verloren gehen, werden diese vor dem Versenden zwischengespeichert. Zur Erzeugung der 360°-Panoramen, werden die empfangenen Frames nach Zeitstempel sortiert und über den Drehwinkel des Laserscanners synchronisiert, indem die Zeitstempel zum ersten und letzten Drehwinkel gespeichert werden. Anschließend werden die Frames über die Zeitstempel per linearer Interpolation den zugehörigen Drehwinkeln zugeordnet.

Alle aufgenommenen Daten werden aus Performanzgründen zunächst in einem Verzeichnis auf dem Kontroll-Laptop abgelegt. Nach der Aufnahme eines Scans findet dann die automatische Kalibrierung und die Generierung der Panoramabilder statt. Das finale Ergebnis wird dann als HDF5-Datei exportiert (WIEMANN ET AL. 2019). Der komplette Aufbau des Systems ist in Abb. 1 illustriert.

3 Klassifikation auf 3D-Hyperspektralpunktwolken

Eine Motivation zum Einsatz des Hyperspektralscanners ist die semantische Interpretation der aufgenommenen Punktwolken. Dazu haben wir in einem ersten Versuch die erstellten Panoramen in das GeoTIFF-Format exportiert und mittels der bekannten EnMAP-Toolbox für das Geoinformationssystem QGIS klassifiziert. Dazu haben wir auf den aufgenommenen Daten Sample-Pixel der Klassen *Grüne Vegetation*, *Gestein*, *Wasser* und *Schatten* markiert und mit entsprechenden Labels versehen. Dabei wurden pro Klasse ca. 13.000 Trainingsamples in den Bildern einer Scanposition markiert und mittels eines Random-Forest-Klassifikators aus der

¹ <https://www.las-vegas.uni-osnabrueck.de/datasets/botanicalgarden1/raw/>

Tabelle 1: Konfusionsmatrix des gelernten Klassifikators auf den Eingangsdaten

	Vegetation	Gestein	Wasser	Schatten
Vegetation	99,84 %	0,01 %	0,00 %	0,00 %
Gestein	0,03 %	98,41%	0,30 %	0,00 %
Wasser	0,11 %	1,57 %	99,70 %	0,00 %
Schatten	0,02 %	0,02 %	0,00 %	100,0 %

Tabelle 2: Konfusionsmatrix nach der Übertragung auf eine weitere Scanposition ohne Helligkeitsangleichung.

	Vegetation	Gestein	Wasser	Schatten
Vegetation	25,22 %	0,00 %	0,00 %	0,00 %
Gestein	0,04 %	53,36 %	0,00 %	0,00 %
Wasser	44,95 %	40,12 %	1,23 %	0,00 %
Schatten	29,97 %	6,52 %	98,77 %	100,0 %

Python-Bibliothek *scikit-learn* klassifiziert. Das Ergebnis der Klassifizierung ist in Abb. 2 zu sehen. Das Bild zeigt einen Scan, der im Botanischen Garten der Universität Osnabrück aufgenommen wurde.

Prinzipiell ist die Klassifikation auf den Trainingsdatensatz in Ordnung. Es fällt allerdings auf, dass an den Übergängen von Vegetation und Schatten Teile der Pflanzen als Wasser klassifiziert werden. Dies zeigt sich auch in der Konfusionsmatrix, die in Tabelle 1 dargestellt ist. Insgesamt zeigt sich das zu erwartende Verhalten, dass der Klassifikator auf den Trainingsdaten sehr gute Ergebnisse liefert. Von besonderem Interesse ist allerdings, ob sich dieser auch auf andere Scanpositionen übertragen lässt, d.h., gut generalisiert. Dazu haben wir ihn auf Beispieldaten angewendet, die am selben Tag innerhalb weniger Minuten an einer ca. 3 Meter entfernten Scanposition aufgenommen wurden. Hier zeigte sich ein deutlich schlechteres Ergebnis als auf den Eingangsdaten, wie in Tabelle 2 zu sehen ist.

Auffällig ist, dass Wasser fast ausschließlich als Schatten klassifiziert wird und zwischen Gestein und Wasser praktisch keine Unterscheidung mehr vorgenommen werden kann. Wasser und Schatten haben insgesamt aufgrund von Reflektion bzw. fehlendem Licht per se relativ schwache Strahlungsintensitäten. Da die zweite Scanposition im Halbschatten lag, waren die gemessenen Intensitäten im Vergleich zu den Originaldaten so gering, dass hier keine signifikanten Unterschiede zwischen den beiden Klassen erkannt werden konnten. Entsprechend haben wir versucht, die Beleuchtungsunterschiede zwischen den Scanposition durch Normalisierung auszugleichen.

4 Offline-Normalisierung

Um den Einfluss der Beleuchtungsstärke zu mindern, haben wir verschiedene Methoden zur pixelweisen Normalisierung der aufgenommenen Daten angewendet. Zunächst haben wir die

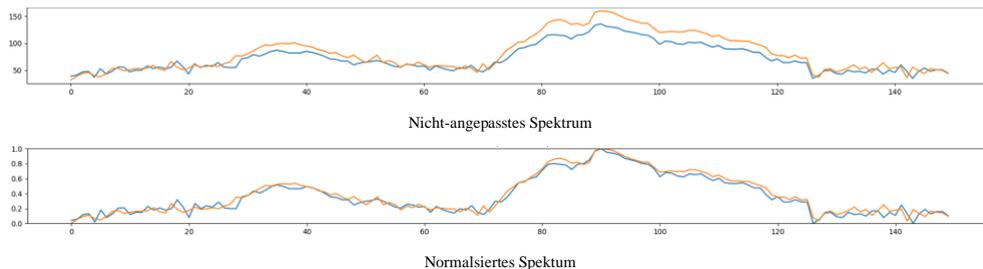


Abb. 3: Vergleich der Spektren eines Pixels derselben Klasse in unterschiedlichen Beleuchtungssituationen vor der Normalisierung (oben) und danach (unten).

Tabelle 3: Klassifikationsergebnisse nach globalem Intensitätsangleich.

	Vegetation	Gestein	Wasser	Schatten
Vegetation	81,61 %	0,49 %	0,25 %	0,02 %
Gestein	0,01 %	71,36 %	2,85 %	0,03 %
Wasser	0,87 %	27,31 %	90,78 %	0,45 %
Schatten	17,51 %	0,78 %	6,13 %	99,50 %

Intensitäten innerhalb eines Scans mittels einer Min-Max-Field-Normalisierung ausgeglichen: $y = \frac{x}{\max(x)}$. Hier werden alle gemessenen Intensitäten auf das Intervall (0, 1) abgebildet. Um die Daten besser vergleichbar zu machen, wurde darüber hinaus auch der mittlere Intensitätswert über mehrere Messungen ermittelt und als Referenzwert für 1 festgelegt: $y = \frac{x}{\text{mean}(x)}$. Mit Hilfe dieser Normalisierung soll die Helligkeit über die verschiedenen Scanpositionen hinweg vergleichbar gemacht werden. Da bei geringer Intensität vermehrt Rauschen auftritt, wurden die Spektren darüber hinaus mit einem Savitzky-Golay-Filter geglättet. Das Ergebnis dieser Offline-Normalisierung ist in Abb. 3 gezeigt.

Die beiden Linien zeigen die Intensitätsverteilungen für Pixel aus der gleichen Klasse, die bei unterschiedlichen Strahlungsverhältnissen aufgenommen wurden. Konkret wurde ein Pixel einer Pflanze, die in der Sonne steht, mit einem Pixel einer Pflanze derselben Art im Schatten verglichen. Ohne Normalisierung zeigen beide kurven qualitativ einen ähnlichen Verlauf, aber mit unterschiedlichen absoluten Intensitäten. Nach der globalen Normalisierung liegen beide Verteilungen nun mehr oder weniger übereinander. Auf diesen Daten haben wir dann den zuvor gelernten Klassifikator erneut angewendet. Das Ergebnis ist in Tabelle 3 zusammengefasst.

Hier zeigt sich, dass sich die Ergebnisse der Klassifikation zwar deutlich verbessert haben, aber immer noch nicht befriedigend sind. Insbesondere wird weiterhin die Klasse *Gestein* sehr oft mit der Klasse *Wasser* verwechselt. Durch den vorgestellten Offline-Vergleich lassen sich die Intensitäten in unterschiedlich ausgeleuchteten Bereich zwar auf ein gemeinsames Niveau angleichen, allerdings sorgen die Glättung und die Änderung des Kontrasts dafür,

dass für die Klassifizierung wichtige Details verloren gehen und daher nur noch schwer unterscheidbar sind, da alle Informationen miteinander in Beziehung gesetzt werden. Dieser

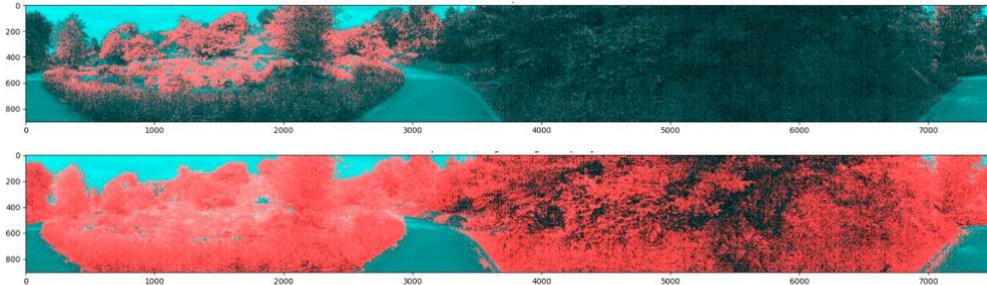


Abb. 4: Klassifikation von Pflanzen vor (oben) und nach der Normalisierung (unten). Vor allem in den Schattenbereich konnte das Ergebnis verbessert werden. Im Bereich der Weggrenzen gibt es allerdings auch vermehrt Fehlklassifikationen.

Effekt ist in Abb. 4 zu sehen. Durch den verstärkten Kontrast werden in den Schattenbereichen mehr Pflanzen klassifiziert als vor der Normalisierung. Im Bereich der Weggrenzen gibt es allerdings viele False-Positives.

5 Online-Beleuchtungsausgleich mit Referenzsensoren

Wie die im vorherigen Abschnitt vorgestellten Ergebnisse zeigen, lassen sich mit einer Nachbearbeitung die Klassifikationsergebnisse zwar verbessern, sind aber leider noch nicht zufriedenstellend. Dies liegt vor allem daran, dass durch den globalen Kontrastausgleich relevante Informationen verloren gehen. Vor allem das Fehlen einer absoluten Referenz, um die tatsächlich eingehende Strahlungsintensität zu bestimmen, ist problematisch. Diese wird allerdings benötigt, um die Winkelabhängigkeit der Einstrahlungsstärke beim Scannen lokal pro aufgenommenen Kamerabild auszugleichen zu können. Da es für realistische Anwendungsfälle nicht möglich ist sicherzustellen, dass in jedem Frame eine Referenz zu sehen ist, wollen wir die Intensität der einfallenden Strahlung durch Miniatur-(STS-)Punktspektrometer ermitteln, die ebenfalls am Scanner angebracht werden. Diese sollen kontinuierlich eine Weiß-Referenz bereitstellen, damit die Intensitäten „on-the-fly“ bei der Datenaufnahme angeglichen werden können.

Die beiden verwendeten Spektrometer messen jeweils in unterschiedlichen Wellenlängenbereichen. Das STS-VIS misst im sichtbaren Bereich von 350 bis 800 nm, das STS-NIR misst bis in den nahen Infrarotbereich (650 bis 1100 nm). Insgesamt decken sie zusammen also den kompletten Spektralbereich ab, der auch von der Hyperspektralkamera erfasst wird. Ein Beispielspektrum bei Messung gegen eine Referenzplatte (95% Weiß) ist im linken Teil von Abb. 5 dargestellt. Die Spektren zeigen die Intensitätswerte, wie sie von den Sensoren geliefert werden. Dabei zeigt sich, dass die absoluten Werte im Überlappungsbereich aufgrund der unterschiedlichen Sensorik nicht direkt vergleichbar sind.

Um die Daten der beiden Spektrometer zu fusionieren, haben wir die Daten des VIS-Spektrometers Überlappungsbereich auf die Werte des NIR-Spektrometers skaliert. Die

resultierenden Skalierungsfaktoren zeigt das mittlere Bild in Abb. 5. An den Verlauf der Werte haben wir eine Exponentialfunktion angefüttet, die dort durch die rote Kurve repräsentiert wird.

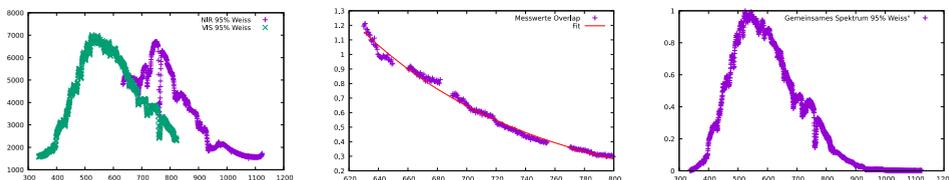


Abb. 5: Fusion der Daten der Spektrometer. Links sind die Rohdaten der beiden Miniaturspektrometer dargestellt. In der Mitte sind die skalierten Werte im Überlappungsbereich sowie die angefüttete Exponentialfunktion gezeigt. Rechts das resultierende gemeinsame Spektrum nach dem Angleich.

Diese Funktion haben wir dann verwendet, um die Werte des NIR-Spektrometers zu skalieren. Das resultierende Gesamtspektrum rechts in Abb. 5 dargestellt. Im Überlappungsbereich passen die Werte sehr gut überein und der Verlauf ist plausibel. Dies planen wir durch weitere Messungen zu validieren.

Um die Intensitätsverläufe von Hyperspektralkamera und Spektrometer vergleichen zu können, haben wir in einem Laborsetup die Spektren der Kamera und Miniaturspektrometer gegen ein hochpräzises vorkalibriertes Referenzspektrometer (SVC HR-1024i) und Referenzplatten (Weiß 95%, Grau 50% und Schwarz 5% Reflektivität) gemessen. Die Spektren und den Messplatz zeigt Abb. 6. Als nächstens werden wir die fusionierten Spektren der Miniaturspektrometer gegen das SVC-Referenzspektrometer matchen, um über diese eine gute Schätzung für die absolut gemessene Einstrahlung zu erhalten. Diese planen wir mittels eines geeigneten Modells auf die Hyperspektralkamera zu übertragen, um einen Online-Ausgleich bereits während der Messung die lokalen Beleuchtungsverhältnisse anzugleichen.

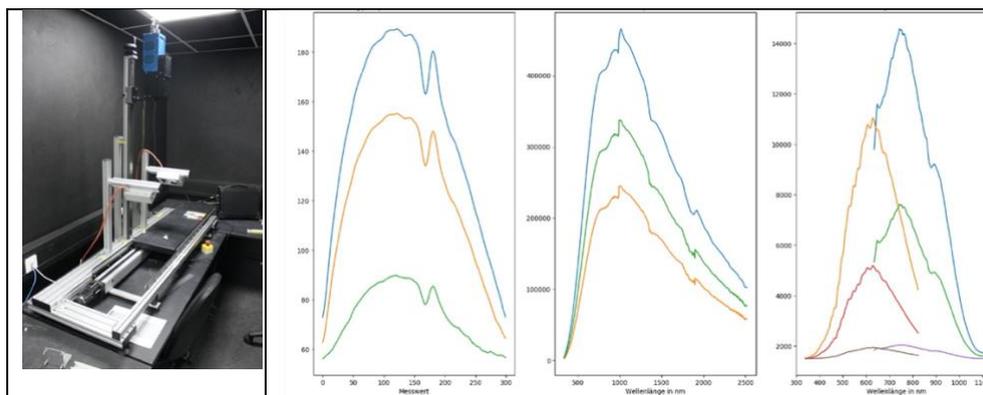


Abb. 6: Der Messplatz zur Kalibrierung der Sensoren sowie die aufgenommenen Referenzspektren für Hyperspektralkamera, Referenz- und Miniaturspektrometer

6 Zusammenfassung und Ausblick

In diesem Papier haben wir erste Ansätze zum Beleuchtungsausgleich für einen terrestrischen Laserscanner vorgestellt. Anhand eines mittels maschinellen Lernens trainierten Klassifikators haben wir gezeigt, dass für eine erfolgreiche Klassifizierung ein Angleich der gemessenen Intensitäten notwendig ist. Durch einen nachträglichen Kontrastausgleich konnte zwar eine Verbesserung der Ergebnisse erreicht werden, für eine zufriedenstellende Klassifikation reicht dieser Ansatz allerdings nicht aus. Daher besteht das Ziel unserer Arbeit darin, die Intensitäten bereits bei der Aufnahme mit geeigneten Sensoren zu bestimmen, und so die beim Scannen auftretenden Beleuchtungsunterschiede auszugleichen. Dazu konnten die Spektren von zwei Miniaturspektrometern bereits erfolgreich fusioniert werden. Die zur vollständigen Kalibrierung notwendigen Daten wurden im Labor erhoben und sollen jetzt dazu verwendet werden, ein vollständiges Modell zum Onlineausgleich zu erstellen.

Im nächsten Schritt wird der Aufbau des Messsystems um die zwei Miniaturspektrometer erweitert. Diese werden ebenfalls an den NanoPC angeschlossen und bei der Datenaufnahme mit den Frames der Hyperspektralkameras assoziiert, um die Intensitäten in den Bildern bereits während des Scanvorgangs an die vorherrschenden Beleuchtungsverhältnisse anzugleichen.

Mit den so aufgenommenen Daten werden wir dann das Klassifikationsexperiment wiederholen, um die Hypothese zu bestätigen, dass die Generalisierbarkeit im Wesentlichen durch die Beleuchtungsunterschiede in den aufgenommenen Scans eingeschränkt wird. Dazu planen wir die terrestrischen Daten auch mit zeitgleich aufgenommenen UAV-Daten derselben Kamera in Verbindung zu setzen, um einen Vergleich mit beleuchtungsunabhängigeren Daten derselben Szene durchzuführen zu können. Das entsprechende Equipment für diese Messungen ist an der Universität Osnabrück bereits vorhanden. In weiteren Arbeiten könnte beim Scannen auch der Sonnenstand zum Zeitpunkt der Messungen berücksichtigt werden, um die Ergebnisse weiter zu verbessern.

Literatur

- Mather, P., & Tso, B. (2016). *Classification methods for remotely sensed data*. CRC press.
- Govender, M., Chetty, K., Naiken, V. und Bulcock, H. (2008): *A comparison of satellite hyperspectral and multispectral remote sensing imagery for improved classification and mapping of vegetation*. Water SA, 34(2), 147-154.

Igelbrink F., Wiemann T., Pütz, S. und Hertzberg J (2018): *Generating High Resolution Hyperspectral Point Clouds on a Mobile Robot*. 15th International Conference on Intelligent Autonomous Systems (IAS-15), Springer 2018

Wiemann, T., Igelbrink, F., Hertzberg J. (2019): *A file structure and reference data set for high resolution hyperspectral 3d point clouds*. 10th IFAC Symposium on Intelligent Autonomous Vehicles IAV 2019. IFAC-PapersOnLine

Bitte geben Sie auf einer separaten Seite zu allen genannten Autoren folgende Informationen:

Dr. Thomas Wiemann
Universität Osnabrück, Institut für Informatik
Arbeitsgruppe Wissensbasierte Systeme
twiemann@uos.de

Alexander Ditt, B. Sc.
Universität Osnabrück, Institut für Informatik
Arbeitsgruppe Wissensbasierte Systeme
aditt@uos.de

Felix Igelbring, M. Sc.
Universität Osnabrück, Institut für Informatik
Arbeitsgruppe Wissensbasierte Systeme
felix.ingelbrink@uos.de

Prof. Dr. Joachim Hertzberg
Universität Osnabrück, Institut für Informatik
Arbeitsgruppe Wissensbasierte Systeme

DFKI-Labor Niedersachsen
Planbasierte Robotersteuerung
joachim.hertzberg@uos.de

