

Photogrammetrische Fernerkundung mit autonomen Mini-Drohnen in der Siedlungshydrologie

Matthew Moy de Vitry¹⁾, Joao P. Leitao²⁾, Piotr Tokarczyk³⁾ und Jörg Rieckermann⁴⁾

¹⁾SkyPlan, Sitten, Schweiz, matthew@skyplan.ch

²⁾Abteilung für Siedlungswasserwirtschaft, Eawag, Dübendorf, Schweiz, joaopaulo.leitao@eawag.ch

³⁾Institut für Geodäsie und Photogrammetrie, ETH Zürich, Schweiz, piotr.tokarczyk@geod.baug.ethz.ch

⁴⁾Abteilung für Siedlungswasserwirtschaft, Eawag, Dübendorf, Schweiz, joerg.rieckermann@eawag.ch

Kurzfassung

In den letzten Jahren wächst der Einsatz von Mini-Drohnen in der Fernerkundung kontinuierlich. In dieser Arbeit haben wir untersucht, wo Drohnen die Fernerkundung von Siedlungen und (Teil-) Einzugsgebieten für die Stadtentwässerung verbessern können. Konkret haben wir untersucht i) ob sich die hochauflösenden digitalen Geländemodellen zur Simulation von Oberflächenabflüssen eignen, ii) Drohnen die Ermittlung von Befestigungsgraden verbessern, iii) wie man automatisch relevante Objekte in den Bildern detektieren kann.

„Unbemannte Luftfahrzeuge“ in der Siedlungswasserwirtschaft?

Seit ungefähr 2008 wächst der Einsatz von sogenannten „unbemannten Luftfahrzeuge“ zur Fernerkundung in der Wissenschaft kontinuierlich. In der Wirtschaft fing diese Zunahme schon einige Jahre früher an (Colomina and Molina 2014), wobei die Anwenderfreundlichkeit dieser „unbemannten Luftfahrzeuge“ stetig zunimmt. Einerseits nimmt die Autonomie und „Intelligenz“ zu, andererseits nehmen sowohl das Gewicht, als auch die Kosten für Hard- und Software drastisch ab. In Bezug auf die Fernerkundung werden vor allem Bilder mit rot-grün-blau (RGB) Daten, sowie anderen Spektralbändern aufgenommen. Neben den detaillierten Bildern kann man mit photogrammetrischen Methoden aus Drohnenbildern extrem hochaufgelöste digitale Geländemodelle (DGM) mit Auflösungen von wenigen Zentimetern zu generieren.

Die Siedlungswasserwirtschaft kann von diesen Entwicklungen profitieren: günstige und hochdetaillierte digitale DGMs ermöglichen es, präzise Überflutungssimulationen anzustellen und Risikoabschätzen zu machen. Fortgeschrittene Algorithmen zur Bilderinterpretation helfen dabei, die Landnutzung, den Befestigungsgrad und relevante Objekte automatisch zu erkennen. Vor allem können mit Drohnen die meisten solcher Untersuchungen von Fachplanern und Betreibern selbständig und ohne grosse Vorlaufzeit durchgeführt werden.

Das Ziel dieser Arbeit war es, zu verstehen wo Mini-Drohnen die Praxis und Forschung im Bereich der Stadtentwässerung verbessern kann, insbesondere was die Fernerkundung von Siedlungen und (Teil-) Einzugsgebieten betrifft. Konkret haben wir drei Fragestellungen untersucht:

- Eignen sich die hochauflösenden digitalen Geländemodellen zur Simulation von Oberflächenabflüssen?
- Verbessern Drohnen die Ermittlung von Befestigungsgraden?
- Wie kann man automatisch relevante Objekte, wie z.B. Einlaufschächte, in den Bildern detektieren?

In diesem kurzen Artikel kann nur ein sehr grober Überblick gegeben werden. Die beschriebenen Methoden und Resultate sind in Moy de Vitry (2014) umfassend dokumentiert.

Methoden

Drohne

Unter Drohne verstehen wir ein unbemanntes und wieder benutzbares Flugzeugsystem, das autonom oder/und ferngesteuert funktionieren kann. Für unsere Studie haben wir eine kleine Drohne mit Deltaflügeln (eBee, Sensefly, Abbildung 1) ausgewählt, die nur 700 Gramm wiegt und von einer Person alleine bedient werden kann. Unser Modell hat eine einfache Consumer-Kamera (Canon IXUS 127 HS), ist aber mit einer Spektral- oder Infrarot-Kamera aufrüstbar. Im Gegensatz zu Quadkoptern kann sie unter guten Umständen 40 Minuten fliegen und mehr als 2 km² aufnehmen, je nach Flugparameter. Sie fliegt komplett autonom dank ihrer Messgeräte, ist aber nicht so „intelligent“ wie andere UAVs, die in Echtzeit ein Modell ihrer Umgebung erstellen, um sich optimal darin bewegen zu können.



Abbildung 1: Ebee-Drohne (Sensefly), die in der Arbeit verwendet wurde

In der Schweiz ist das fliegen von Drohnen ohne Ausweis in den meisten Fällen erlaubt, insofern die Drohne immer im Sicht ist und die Kontrolle in jeder Zeit wieder genommen werden kann. In den Kontrollzonen von Flughäfen gibt es eine Höhengrenze von 150 m, und in einem Umkreis von 5 km vom Flughafen ist eine Bewilligung Pflicht (UVEK 2014). Auch wenn man über Menschengruppen fliegen will, braucht man eine Bewilligung.

Im Folgenden beschreiben wir kurz die verwendeten Methoden i) zur photogrammetrischen Erstellung der digitalen Geländemodelle, die wir zum Vergleich herangezogen haben, ii) zur statistischen Klassifikation des Befestigungsgrades und iii) von Einlaufschächten.

Photogrammetrische Methoden zur Generierung von digitalen Geländemodellen

Mit photogrammetrischen Methoden können digitale Geländemodelle (DGM) mit einfachen Bildern erzeugt werden, ohne ein aktives Messgerät wie einen Laser (LiDAR) auf der Drohne tragen zu müssen. Die Bilder werden folgendermassen prozessiert:

1. Zuerst werden in allen Bildern charakteristische Punkte erkannt und zugeordnet. Sie bilden ein erstes und etwas ungenaues DGM.
2. Dieses DGM wird anhand von Referenzpunkten georeferenziert und optimiert. Die Referenzpunkte müssen in den Bildern sichtbar sein und ihre Koordinaten müssen bekannt sind. Wir haben gute Erfahrungen damit gemacht, temporäre Markierungen, z.B. mit kontrastreichem breitem Klebeband, im Einzugsgebiet anzubringen.
3. Das georeferenzierte Modell wird dann verdichtet, um auch weniger auffällige Punkte ins Modell mit einzubeziehen.
4. Da das Modell noch Fehlerpunkte beinhaltet, wird es noch mit speziellen Filter-Algorithmen geglättet, die darauf optimiert sind Ausreisser zu entfernen.

Zur photogrammetrischen Verarbeitung (Punkt 1.-3.) haben wir die Software Pix4D (Pix4D Development Team 2014) verwendet, die auf die Prozessierung von Drohnen-Bildern spezialisiert ist und ein einfaches Interface anbietet.. Die open-source Software CloudCompare (Girardeau-Montaut 2011) wurde zur Glättung verwendet (4.).

Analyse der digitalen Geländemodelle und Oberflächenabfluss-Experimente

In unserer Studie haben wir die selbst generierten DGMs mit dem schweizerischen digitalen Geländemodell SwissALTI3D verglichen, welches hauptsächlich mit LiDAR erstellt wird. SwissALTI3D hat eine Auflösung von 2m und eine vertikale Genauigkeit von $\sigma=0.5\text{m}$ (s) und stellt einen quasi-Standard für die Ermittlung von Überflutungsflächen dar.

Zur Beurteilung der Eignung zur 2D-Simulation des Oberflächenabflusses haben wir in einem 4-ha grossen Gebiet für beide Modelle neben visuellen Aspekten vor allem drei Indikatoren quantitativ ausgewertet:

1. den **Fliessweg des Oberflächenabflusses** auf den Strassen. Diese wurden mit dem „Flow Accumulation“ Algorithmus berechnet, welcher als SAGA-Anwendung in QGIS (QGIS Development Team 2014) zur Verfügung steht.
2. den **Gradienten und die Richtung des Geländes**. Diese wurden mit QGIS berechnet.
3. den **mittleren Fehler über einer freien Fläche**. Dieser wurde durch den mittleren quadratischen Gesamtfehler („root-mean-squared-deviation (RMSD)“) beschrieben. Dazu haben wir einen Profil über einer flachen Strecke ausgehört und daran ein lineares Regressions-Modell gefittet. Die ermittelten Residuen beschreiben den RMSD.

Zur Validierung der Analysen des Fliessweges haben wir diese auch experimentell bestimmt. Dazu wurde Wasser auf der Oberfläche ausgegossen und anschliessend der resultierende Abstand des Fliessweges zum Bordstein aufgenommen.

Befestigungsgrad

Die Bestimmung der Befestigungsgrade eines Einzugsgebiets mit der Klassifizierung von Luftbildern ist altbekannt, aber die Anwendung von Drohnen zu diesem Zweck noch nicht. Sie bietet einige Vorteile im Vergleich zu konventionellen Auswertungen: Erstens können Drohnen eine sehr flexible Lösung sein, besonders für mittlere und kleinere Teileinzugsgebiete und Ortschaften, die sich baulich verändern. Weil Aufnahmen kurzfristig geplant werden können, ist es möglich Bilder für die Entwässerungsplanung zeitnah aufzunehmen, zu aktualisieren oder detaillierte Aufnahmen von besonders gefährdeten Gebieten zu machen. Da die Drohne unter den Wolken fliegen kann, ist man weniger abhängig vom Wetter und kann auch im Winter bei möglichst diffusem Licht fliegen und so gezielt Bilder mit sehr wenig Vegetation und Schatten aufnehmen, die sonst oft die Analyse verfälschen. Für die maschinelle Ermittlung des Befestigungsgrades haben wir einen neuen Klassifizierungs-Algorithmus verwendet, der auf Boosting basiert und visuelle Strukturen von Kombinationen aus allen Spektralbändern als Merkmale verwendet (Tokarczyk et al. 2014).

Die Grundidee hinter Boosting ist, erstens, möglichst viele sogenannte „textuelle Merkmale“ zu extrahieren. Zweitens werden in einer Trainingsphase nur diejenigen Merkmale ausgewählt, die informativ sind, d.h. bestimmte Kriterien ausfüllen (hier: Trainingsfehler minimieren). Dieses ist der grösste Vorteil im Vergleich zu herkömmlichen Klassifikationsmethoden, wie z.B. „Maximum-Likelihood“, denn es befreit den Analytisten von der manuellen Auswahl von Merkmalen. Manuell ausgewählte Merkmale basieren oft auf der subjektiven Einschätzung des Analytisten oder einiger weniger Experten. Sie können daher limitierend wirken, wenn sie wenig Information für das Klassifizierungs-Problem beinhalten. Ausserdem, ist beim Boosting die Menge der von einem Bild erhaltenen Information alleine aufgrund der riesigen Anzahl von extrahierten Merkmalen grösser. In unserer Arbeit wurde die Klassifizierung entweder mit zwei (durchlässig/undurchlässig) oder drei (Vegetation/Gebäude/Strassen, Wege) Zielklassen durchgeführt.

Zur Bestimmung der Güte der Klassifizierung benutzen wir die Gesamtgenauigkeit (engl.: „Overall Accuracy“). Die Klassifizierung wurde auf drei Ebenen evaluiert. Erstens vergleichen wir die neuen, mittels boosting ermittelten, Merkmale mit herkömmlichen Merkmalen, die traditionell auf der lokalen Auswertung angrenzender oder benachbarter Pixel basieren. Zweitens untersuchen wir, wieviele Trainingsdaten benötigt werden, um eine gute Gesamtgenauigkeit der Klassifizierung zu bekommen. Dieser Aspekt ist wichtig, da die Zeit zum Trainieren des Klassifikators von der Anzahl der Trainingsdaten abhängig ist. Drittens vergleichen wir die erzielte Güte für die zwei unterschiedlichen Bild-Datensätze.

Automatische Einlaufschachterkennung

Für die Erkennung von Einlaufschächten (Abbildung 2) benutzen wir den Viola-Jones Detektor, der oft eine sehr effiziente Klassifizierung auf grossen Mengen von Bildern erzielt (Viola and Jones 2001) und daher in fast allen

Systemen zur Gesichtserkennung eingesetzt wird. Wie in der Gesichtserkennung muss der Viola-Jones Detektor auch hier mit tausenden von positiven und negativen Beispiel-Bildern trainiert werden. Als Auflösung für das Training haben wir 4 cm/Pixel bestimmt. Um den Prozess zu beschleunigen, verringern wir zuerst die Grösse der Bilder. Dazu verwenden wir die Lage der Strassen als eine Schablone, um die Suche auf relevante Bereiche zu begrenzen. Hierzu können nicht nur Strassenkataster sondern auch das frei verfügbare OpenStreetMap verwendet werden.

Um den Detektor zu verbessern haben wir „Hard Negative Mining“ angewendet. Dazu wird der Detektor zunächst auf einem großen markierten Datensatzes trainiert. In den nächsten Schritten werden wiederholt die Datensätze mit den größten Detektionsfehlern zum Trainings-Datensatz hinzugegeben und der Detektor erneut trainiert. So werden diese Fehler in der nächsten Generation des Detektors idealerweise vermieden. Unser Programm verwendet die Bibliotheken OpenCV (Bradski 2000) für die Bilderinterpretation und GDAL (Warmerdam 2008) für die Bearbeitung von georeferenzierte Objekte. Sie wurde in Python (Sanner 1999) implementiert.

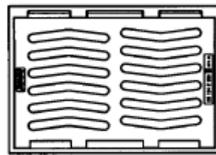


Abbildung 2: Beispiel eines typischen schweizer Einlaufschacht-Gitters (www.bgs.ch)

Fallstudien

Drei Fallstudien dienen als Datenbasis für unsere Studie. Alle drei Fallstudien waren in der Schweiz und wurden während der Studie ausgeführt.

Entwicklung der Methoden (Adliswil, Zürich)

In Adliswil, einer Vorstadt von Zürich, haben wir zunächst zwei verschiedene Gebiete untersucht, um einerseits die Generierung der Geländemodelle besser zu verstehen und andererseits die Methoden zur Einlaufschachterkennung zu entwickeln. Für die erste Fragestellung sind wir in einen kleinen 4-ha Gebiet 14 Mal geflogen und haben dabei die Flugparametern i) Höhe, ii) Kamera-Neigung, iii) Grad der Bildüberlappung und iv) Wetterbedingungen variiert. Zweitens sind wir über einem 40-ha Gebiet einmal geflogen (Abbildung 3). Die Auflösung der Aufnahmen war zwischen 2.5 und 10 cm/Pixel. Aus den hochauflösenden Bildern wurden die positiven und negativen Beispiele für den Einlaufschachterkennungsalgorithmus generiert. Auch das „Hard Negative Mining“ wurde mit diesen Bildern gemacht.



Abbildung 3: Orthophoto des grösseren Einzugsgebiets für das Fallbeispiel in Adliswil.

Benchmarking der Bestimmung der Befestigungsgrade (Stadt Luzern)

Die Stadt Luzern bietet einen interessanten Vergleich, das sie zur Zeit ihren generellen Entwässerungsplan (GEP) aufdatieren und dazu im Jahr 2013 die Befestigungsgrade anhand einer Luftbildauswertung ermittelt

haben. Zum Vergleich ihrer Ergebnisse mit sehr hochauflösten Drohnen-Bildern haben wir ein Gebiet von 163 ha mit einer Auflösung von 10 cm/Pixel erfasst (Abbildung 4). Da Luzern ein Kataster der Einlaufschächte hat, wurde hier die Objekterkennung getestet. Dazu haben wir Aufnahmen eines kleineren Teilzugsgebietes mit einer Auflösung von 4 cm/Pixel gemacht.



Abbildung 4: Orthophoto des Fallstudie-Gebiets in Luzern

Benchmarking der Einlaufschachterkennung (Köniz, Bern)

Die Gemeinde Köniz ist eine der wenigen Gemeinden, die ihre Einlaufschächte mit hoher Genauigkeit in einem Kataster aufgenommen hat. Diese hohe Qualität ermöglichte es uns nicht nur zu quantifizieren, wie viele der aus der Luft sichtbaren Schächte vom Detektor erkannt wurden, sondern auch wie viele Schächte aus der Luft gar nicht sichtbar sind. Vor allem Letzteres bestimmt, ob die Luftbild-basierte Einlaufschachterkennung überhaupt Sinn macht. Um die Güte der Einlaufschachterkennung zu quantifizieren wurde der anhand der Adliswil-Daten trainierte Detektor für Luzern weder angepasst noch weiter trainiert.

Das Orthophoto (entzerrtes Luftbild) von Köniz bildet eine Fläche von fast 30 ha mit einer Auflösung von 4 cm/Pixel ab (Abbildung 5). Für Köniz wurde ebenfalls der anhand der Adliswil-Daten trainierte Detektor verwendet.



Abbildung 5: Orthophoto des Fallstudien-Gebiets in Köniz, Bern

Ergebnisse und Diskussion

Digitale Geländemodelle

Im Vergleich zur SwissALTI3D gibt es einige Vorteile der selbst erstellten DGMs: zum Beispiel waren das Rauschen (als RSMD) in unserem Test kleiner, und die simulierten Fließpfade waren etwas realistischer als beim SwissALTI3D (Abbildung 6). Im Beispiel ist die Überlegenheit sichtbar, selbst wenn das selbsterstellte DGM für einen fairen Vergleich auf 2m herunterskaliert wurde. Das bestätigt ähnliche Ergebnisse basierend auf hochaufgelösten LiDAR-Untersuchungen gefunden haben (Sampson et al. 2012)

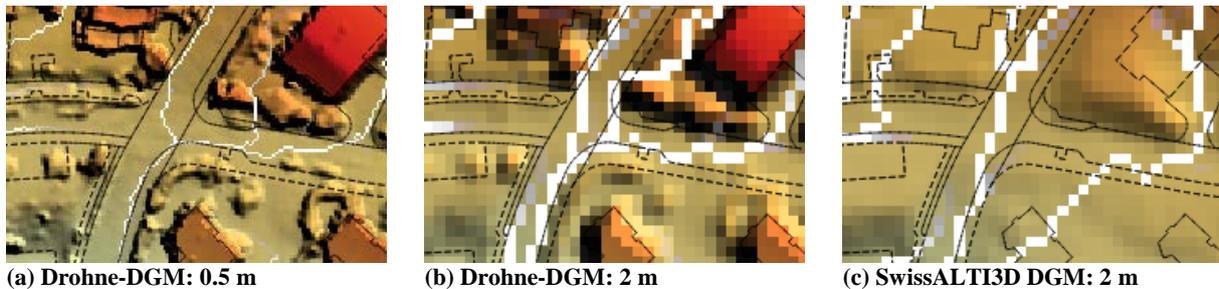


Abbildung 6: Fließlinien der unterschiedlichen Modelle (schwarze Linien: Kataster)

Trotz der positiven Resultate muss man sich der Limitierungen von photogrammetrischen Fernerkundungen bewusst sein. Schwierigkeiten ergeben sich vor allem dort, wo die Bild-Information suboptimal ist. : So sind Strassen oft sehr gleichförmig und weisen wenig visuelle Strukturen auf. Dieses führt zu grossem Rauschen im DGM und erschwert genaue Abflusssimulationen von Oberflächenabflüssen. Einen anderen Effekt haben Bäume, die eine sehr komplizierte Struktur haben und Löcher im DGM verursachen (Abbildung 7, Rechteck links). Dieses lässt sich durch eine sehr grosse Bilderüberlappung verringern. Schwierigkeiten entstehen auch durch Schatten und sehr dunkle Zonen, wie z.B. Tiefgaragen-Einfahrten oder Treppenhäuser, die keine oder nur sehr wenig Bild-Informationen bieten.

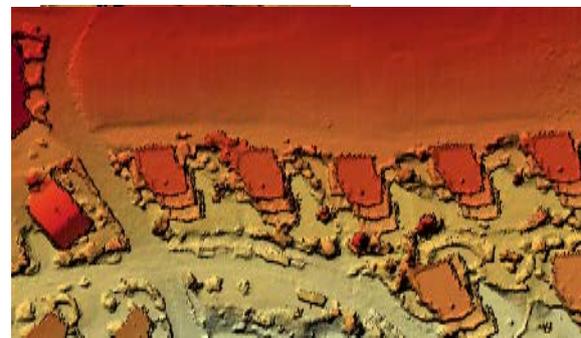


Abbildung 7: Beispiel eines mittels Drohne selbsterstellten DGMs (rechts: Detail)

Unter anderem wegen des Informationsverlustes in dunklen Zonen wird Photogrammetrie das Laserscanning in Zukunft wahrscheinlich nicht ersetzen, sondern sich parallel entwickeln und es ergänzen (Leberl et al. 2010). Bereits heute gibt es Drohnen die gleichzeitig mit LiDAR Fotografie aufnehmen. Für die Siedlungsentwässerung sind diese besonders vorteilhaft, da die Höhengenaugigkeit wesentlich besser ist als in reinen photogrammetrischen Modellen. Ausserdem stellt das generierte Model den Boden und nicht die Oberfläche dar. Der Vorteil der photogrammetrischen Modelle sind eindeutig das geringe Gewicht und die Kosten.

Befestigungsgrad

In Bezug auf die Gesamtgenauigkeit der Klassifizierung des Befestigungsgrads haben wir für die drei verschiedenen Kriterien die folgenden Ergebnisse gewonnen. Erstens zeigt sich, dass mit den neuen per boosting entwickelten Merkmalen die gleichen, oder sogar leicht schlechtere Resultate erzielt werden, als mit den herkömmlichen Merkmalen die auf der lokalen Analyse benachbarter Pixel basieren. Zweitens zeigt sich, dass beim boosting schon mit 1% der Trainingsdaten (was ca. 10'000 Pixels entspricht) eine sehr gute Gesamtgenauigkeit von mehr als 95% erzielt werden.

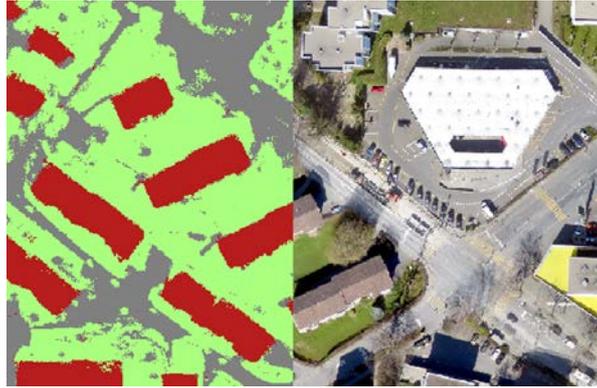


Abbildung 8: Automatische Klassifizierung des Orthophotos in Luzern

Drittens erhalten wir mit den selbsterstellten Bildern der Drohnen eine Gesamtgenauigkeit, die mit der von hochauflösenden Orthophotos aus professionellen Luftbildaufnahmen vergleichbar ist und nur 0.5– 2% schlechter ist. (Tabelle 1).

Tabelle 1: Gesamtgenauigkeit der verschiedenen Klassifizierungsmethoden

		Anteil Trainingsdaten	1%	2%	5%
21x21 Pixel Nachbarschaft	Konventionelle Luftbilder		95.0%	95.7%	96.4%
	Drohne-Luftbilder		94.8%	95.3%	95.9%
Neuentwickelte Merkmale	Konventionelle Luftbilder		95.6%	95.8%	96.3%
	Drohne-Luftbilder		93.7%	94.3%	95.2%

Einlaufschachterkennung

Für unsere Fallbeispiele erzielen wir Detektionsraten von bis zu 70% der sichtbaren Schächte erkennen (relative Erkennungsrate). Die Güte der Ergebnisse hängt dabei stark vom verwendeten Detektor ab und im Allgemeinen geht eine hohe Detektionsrate auch mit sehr vielen falschen positiven Detektionen einher (Abbildung 9). Weil die Güte ausserdem stark von der Maskierungsmethode und vom Redundanzkriterium abhängt (Abbildung 9 & Abbildung 11), lassen sie sich im Moment nur schwer verallgemeinern. Eine gute Strategie scheint, erstens, zu sein, anstelle von ganzen Strassen nur die Bordsteinkanten mit einem Puffer als Maske zu nehmen, und, zweitens, ein Redundanzkriterium von drei Nachbarn¹ zu wählen. So haben wir eine Erkennungsrate von 40% und eine Fehlerfreiheit von 50% (Abbildung 9, 3. Säulenpaar).

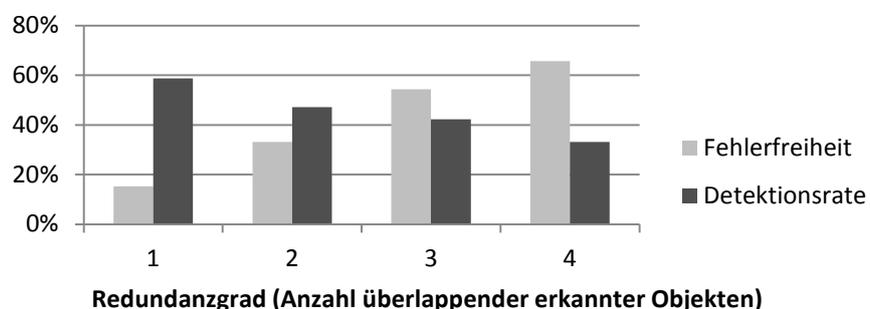


Abbildung 9: Güte des Algorithmus bei verschiedenen Redundanzgraden.

¹Die Anzahl überlappender erkannter Objekte

Weiteres Verbesserungspotenzial sehen wir bei der Auswahl der Merkmale und beim Training des Detektors. Hier scheint vor allem das „Hard Negative Mining“ sehr erfolgversprechend, was wir in unserer Studie leider nicht vertiefen konnten (Abbildung 10: Resultate für wiederholtes „).

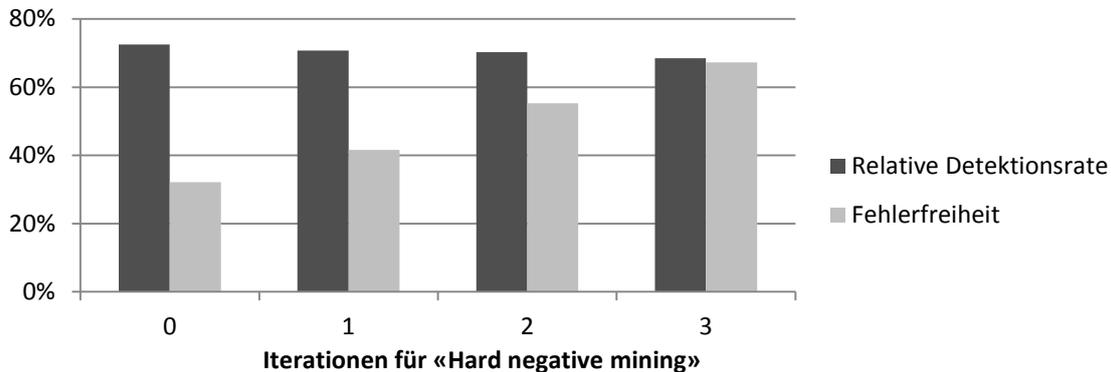


Abbildung 10: Resultate für wiederholtes „Hard Negative Mining“ für das Fallbeispiel in Adliswil

In Bezug auf die Maskierungsmethode ist die Verwendung von OpenStreetMap (OSM) sehr attraktiv, weil sie fast überall in der Welt verfügbar ist und die Resultate deutlich verbessert (Abbildung 11). Leider ist ihre Genauigkeit und Vollständigkeit viel schlechter als im Schweizer Kataster. Die OSM-Maske benötigt daher einen vergleichsweise grösseren Puffer, was zu mehr falschen positiven Detektionen führt.

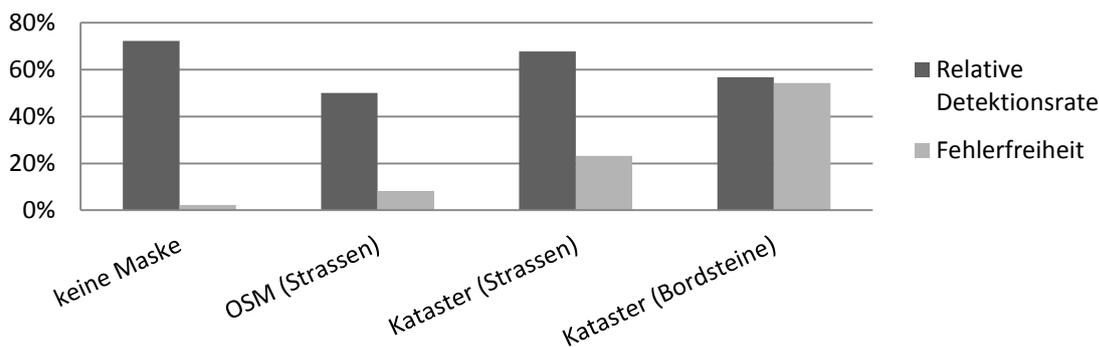


Abbildung 11: Einfluss der Maske auf die Güte des Detektors (Köniz)

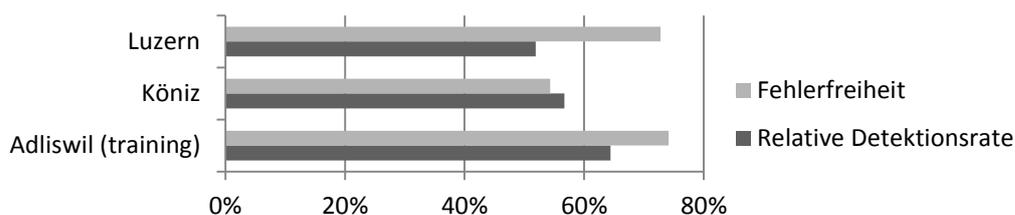


Abbildung 12: Leistung vom Programm in verschiedenen Fallstudien

Interessanterweise sind die Detektionsraten in den verschiedenen Fallstudien sehr ähnlich, obwohl der Algorithmus nur mit dem Adliswil-Datensatz trainiert wurde (Abbildung 12). Das ist einerseits ein Hinweis darauf, dass die Methode für die Einlaufschachterkennung ziemlich robust ist. Andererseits ist zu vermuten, dass ein zusätzliches Training mit lokalen Daten die Detektion verbessern kann.

In Köniz haben wir die Güte des Detektors mit den Referenzdaten aus der GPS-gestützten manuellen Vermessung vergleichen können. Es ergab sich, dass 20% aller Schächte unter Bäume verborgen waren.

Insgesamt zeigt es sich, dass die automatische Detektion von Einlaufschächten nicht trivial ist und konsistent zu hohen Fehldetektionen führt. Für die praktische Anwendung wäre daher zur Zeit eine semi-automatische Detektion zu empfehlen. Mit einer Kombination von automatischer Detektion als Prä-prozessor und anschliessende manuelle Elimination der falschen positiven Detektionen in den Luftbildern haben wir die Detektionsrate von 70 auf 74% aller Schächte verbessert.

Interessanterweise zeigten unsere hochaufgelösten Luftbilder, dass die Referenzdaten selbst erstaunlich viele Fehler aufwiesen. So konnte die semi-automatische Klassifikation die manuellen Ergebnisse so um 5% verbessern.

Schlussfolgerungen

- Hochaufgelöste Bilddaten von Drohnen haben ein grosses Potenzial in der Siedlungsentwässerung, da sie bessere Grundlagendaten liefern als manche aktuellen LiDAR-Geländemodelle, und sehr flexible und zeitnahe Einsätze ermöglichen.
- Ein Vergleich der selbsterstellten digitalen Geländemodelle mit in der Schweiz kommerziell erhältlichen zeigt, dass die ersteren besser für Simulationen von Oberflächenabflüssen geeignet sind. Insbesondere liefern sie realistischere Oberflächen-Fließwege und ausserdem ein geringeres Rauschen in Strassen. Ausserdem bilden sie die Bordsteinkanten ab. Wie zu erwarten haben sie allerdings Schwierigkeiten bei Vegetation, wie z.B. Bäumen.
- Die Ermittlung des Befestigungsgrades anhand von Drohnen-Bildern zeigt, dass das Boosting-Verfahren eine Gesamtgenauigkeit von 95% und mehr ermöglicht. Dieses funktioniert im Wesentlichen auch mit herkömmlichen Merkmalen, die auf der lokalen Nachbarschaft von Pixeln basieren. Dabei wurde schon mit einem Trainingsdatensatz von 1% der gesamten Daten, immerhin noch 10'000 Pixel, eine gute Gesamtgenauigkeit erzielt. Insgesamt liefern die Auswertungen mit Drohnen-Bildern praktisch die gleichen Resultate wie mit hochaufgelöste Orthophotos aus professionellen Luftbildaufnahmen.
- Für die Objekterkennung bilden die Drohnen-Bilder aufgrund der hohen Auflösung ebenfalls eine gute Grundlage. Für den Spezialfall der Erkennung von Einlaufschächten werden Detektionsraten um die 70% erzielt. Hier besteht wahrscheinlich noch einiges Verbesserungs-Potenzial in Bezug auf die Auswahl von Merkmalen und die Klassifikations-Methode. Die semi-automatische Klassifikation kann derzeit bis zu 90% der sichtbaren Einlaufschächte erkennen und so dazu beitragen, die manuelle Erkennungsrate, die ebenfalls erstaunlich fehlerbehaftet ist, um 5% zu verbessern.
- Die Entwicklung von Drohnen-Plattformen ist extrem dynamisch und es werden ständig unzählige spezialisierte Typen und Software entwickelt. Für die Auswahl einer Plattform unbedingt vom Spezialisten beraten lassen. In Zukunft ist es zu erwarten, dass kleinere Sensoren mit höherer Auflösung die Ergebnisse deutlich verbessern werden. Grosses Potenzial in Multi-spektralen Sensoren, ggf. ergänzt mit Laser.
- Aufgrund der aktuellen Entwicklungen im Bereich ist in Zukunft mit einer zunehmenden Regulierung zu rechnen. Aufwendige Bewilligungen könnten vor allem flexible Einsätze stark einschränken.

Danksagungen

Diese Arbeit wäre ohne die Hilfe von verschiedenen Leuten nicht möglich gewesen. Wir danken Prof. Konrad Schindler (ETHZ) und Andreas Scheidegger für wertvolle Hinweise zur Datenerhebung und -analyse. Wir danken ebenfalls Michael Jeskulke, Beat Tinner, Markus Flückiger, Tobias Doppler, Prof. Max Maurer, Rosi Siber und Michael Döring für ihre Unterstützung. Insbesondere bedanken wir uns bei der Firma Holinger AG, dem Tiefbauamt der Stadt Luzern und bei der Gemeinde Köniz für die speditive und erfolgreiche Zusammenarbeit bei den Fallstudien.

Literatur

- Bradski, Gary. 2000. "The Opencv Library." *Doctor Dobbs Journal* 25 (11): 120–26.
- Colomina, I., and P. Molina. 2014. "Unmanned Aerial Systems for Photogrammetry and Remote Sensing: A Review." *ISPRS Journal of Photogrammetry and Remote Sensing* 92: 79–97. doi:<http://dx.doi.org/10.1016/j.isprsjprs.2014.02.013>.
- Girardeau-Montaut, Daniel. 2011. "CloudCompare-Open Source Project." *OpenSource Project*. www.cloudcompare.net.
- Leberl, Franz, Arnold Irshara, Thomas Pock, Philipp Meixner, Michael Gruber, Susanne Scholl, and Alexander Wiechert. 2010. "Point Clouds: LIDAR versus 3D Vision." *Photogrammetric Engineering and Remote Sensing* 76: 1123–34.
- Moy de Vitry, Matthew. 2014. "Improving Urban Flood Management with Autonomous Mini-UAVs." Master Thesis, Zürich: ETHZ.
- Pix4D Development Team. 2014. "Pix4Dmapper Software Manual." *PixD Support*. <https://support.pix4d.com/entries/28216826>.

-
- QGIS Development Team. 2014. *QGIS Geographic Information System*. Open Source Geospatial Foundation. <http://qgis.osgeo.org>.
- Sampson, Christopher C., Timothy J. Fewtrell, Alastair Duncan, Kashif Shaad, Matthew S. Horritt, and Paul D. Bates. 2012. "Use of Terrestrial Laser Scanning Data to Drive Decimetric Resolution Urban Inundation Models." *Advances in Water Resources* 41 (June): 1–17. doi:10.1016/j.advwatres.2012.02.010.
- Sanner, Michel F. 1999. "Python: A Programming Language for Software Integration and Development." *J Mol Graph Model* 17 (1): 57–61.
- Tokarczyk, P., J.D. Wegner, S. Walk, and K. Schindler. 2014. "Features, Color Spaces, and Boosting: New Insights on Semantic Classification of Remote Sensing Images." *IEEE Transactions on Geoscience and Remote Sensing* Early Access Online. doi:10.1109/TGRS.2014.2321423.
- UVEK. 2014. *Verordnung des UVEK über Luftfahrzeuge besonderer Kategorien*. Accessed May 28. <http://www.admin.ch/opc/de/classified-compilation/19940351/index.html>.
- Viola, Paul, and Michael Jones. 2001. "Robust Real-Time Object Detection." In *International Journal of Computer Vision*.
- Warmerdam, Frank. 2008. "The Geospatial Data Abstraction Library (GDAL)." In *Open Source Approaches in Spatial Data Handling*, 87–104. Springer.