Dreiländertagung der DGPF, der OVG und der SGPF in Wien, Österreich – Publikationen der DGPF, Band 28, 2019

Klassifikation hochaufgelöster LiDAR- und MVS-Punktwolken zu Monitoringzwecken

MICHAEL KÖLLE¹, DOMINIK LAUPHEIMER¹ & NORBERT HAALA¹

Zusammenfassung: Die erreichbare Genauigkeit bei der Erfassung raumbezogener Daten durch Methoden der Photogrammetrie sowie des Airborne Laserscannings (ALS) von Unmanned-Aerial-Vehicles (UAVs) ermöglicht mittlerweile auch Anwendungen wie das Monitoring von Bauwerksdeformationen oder Bodensenkungen. Unerlässliche Voraussetzung hierfür ist die Identifizierung und Elimination zeitlich veränderlicher Bereiche wie Vegetation aus den erfassten Punktwolken, um die Bestimmung der Deformationen auf sinnvolle Bereiche zu fokussieren. Für eine dementsprechend erforderliche Klassifikation werden sowohl geeignete geometrische Merkmale aus einer LiDAR- bzw. Multi-View-Stereo (MVS)-Punktwolke als auch radiometrische Merkmale aus den zugehörigen Bilddaten abgeleitet. Diese werden anschließend neben dem klassischen Random-Forest-Klassifikator (RF) auch vergleichend einem auf Merkmalen basierenden Multi-Branch 1D-Convolutional Neural Network (CNN) dargeboten.

1 Einleitung

Sowohl Airborne Laserscanning (ALS)- als auch Multi-View-Stereo (MVS)-Daten, die von Unmanned-Aerial-Vehicle (UAV)-Plattformen aus erfasst werden, haben mittlerweile ein Genauigkeitspotential nahe dem Millimeterbereich erreicht. Dies macht Anwendungen wie die Erfassung von Deformationen von Bauwerken oder geologischer Setzungen des Geländes möglich, und zwar mit deutlich größerer Flächenleistung als die klassische Ingenieurgeodäsie. Dies wird am Beispiel des mit der Bundesanstalt für Gewässerkunde (BfG) durchgeführten Projekts Hessigheim (CRA-MER et al. 2018) demonstriert, wobei dieses Gebiet nahezu zeitgleich mit einem photogrammetrischen Kamerasystem und einem LiDAR-System beflogen worden ist. Damit kann auf zwei Punktwolken unterschiedlicher Charakteristika zurückgegriffen werden. Eine weitere Besonderheit dieser Daten liegt in der extrem hohen räumlichen Dichte der aufgenommenen Punkte im LiDAR-Fall (ca. 800 Punkte/m²) bzw. der mit *Agisoft PhotoScan* (AGISOFT 2018) prozessierten Punkte im MVS-Fall (ca. 8000 Punkte/m²).

Im Hinblick auf potentielle Höhenänderungen aufgrund von möglichen Setzungen des Geländes soll zunächst in den beiden Datensätzen der ersten Epoche automatisch zwischen festen, nichtvertikalen Flächen, d.h. *Geeignet für Monitoring*, und dynamischen Flächen, d.h. *Ungeeignet für Monitoring*, unterschieden werden. Neben einer binären Klassifikation erfolgt zusätzlich eine solche, die diese beiden Klassen im Sinne einer Mehrklassenklassifikation jeweils weiter unterteilt. Damit ist eine universell anwendbare semantische Segmentierung gegeben, welche im Folgenden im Fokus steht. Die Klassifikation erfolgt mittels des klassischen Random-Forest-Klassifikators

¹ Universität Stuttgart, Institut für Photogrammetrie, Geschwister-Scholl-Str. 24D,

D-70174 Stuttgart, E-Mail: [michael.koelle, dominik.laupheimer, norbert.haala]@ifp.uni-stuttgart.de

(RF) unter Verwendung geometrischer sowie radiometrischer Merkmale, wobei letztere im Li-DAR-Fall speziell abgeleitet werden. Da sich Convolutional Neural Networks (CNNs) immer mehr als erfolgreiches Werkzeug für die Klassifikation von Punktwolken erweisen (z.B. ZHAO et al. 2018), wird auch eine Klassifikation mittels des Ansatzes eines Modellwissen in Form von Merkmalen nutzenden Multi-Branch 1D-CNN nach GEORGE et al. (2018) angewandt.

2 Semantische Interpretation der Punktwolken

Der im Rahmen dieser Arbeit vorgestellte Ansatz zur semantischen Interpretation der Punktwolken gliedert sich in drei Schritte. Zunächst werden entsprechende Referenzdaten für das Interessensgebiet erzeugt, indem auf Grundlage einer geeigneten Klassenfestlegung ein manuelles Labeln der Daten erfolgt (Kap. 2.1). Nachfolgend gilt es, die für die Klassifikation notwendigen geometrischen und radiometrischen Merkmale für die einzelnen Punktprimitive zu extrahieren (Kap. 2.2). Darauf aufbauend können die einzelnen Datensätze mittels RF und Multi-Branch 1D-CNN klassifiziert werden (Kap. 2.3).

2.1 Klassendefinition und Ableitung der Referenzdaten

Für das Training und die Evaluierung eines Klassifikators müssen jeweils gelabelte, in Trainings-, Validierungs- und Testdaten untergliederte Referenzdaten zur Verfügung stehen. Diese werden für die geplante Anwendung in Anlehnung an NIEMEYER et al. (2014) jeweils detailliert in 11 Klassen unterteilt, welche Abb. 1 entnommen werden können. Deren Vertreter sollen anschließend durch einen Klassifikator automatisch identifiziert werden.



Abb. 1: Ausschnitt der gelabelten LiDAR-Punktwolke (0=*Stromleitung*, 1=*Niedrige Vegetation*, 2=*Versiegelte Fläche*, 3=*Fahrzeug*, 4=*Sonstige Ausstattung*, 5=*Dach*, 6=*Fassade*, 7=*Strauch/Hecke*, 8=*Baum*, 9=*Offener Boden/Geröll*, 10=*Vertikale Fläche*).

Für den verfolgten Anwendungszweck des Monitorings bezüglich Senkungen des Geländes ist bereits eine binäre Klassifikation in *Geeignet für Monitoring* und *Ungeeignet für Monitoring* ausreichend. In der Klasse *Geeignet für Monitoring* können lediglich die Klassen *Versiegelte Fläche* und *Dach* als fest annehmbare, nicht-vertikale Flächen vereinigt werden und in das angestrebte Deformationsmodell eingehen.

2.2 Merkmalsextraktion

Die zur beabsichtigten Klassifikation der Punktprimitive zu extrahierenden Merkmale müssen im Falle von Punktwolken in der Regel im Zusammenhang mit umgebenden Primitiven bestimmt werden. Als geeignete Nachbarschaftsdefinitionen werden sowohl eine Kugel- als auch eine Zylindernachbarschaft im Sinne einer Multiskalenanalyse, jeweils mit Radien von 1, 2, 3 und 5 m angesetzt (WEINMANN et al. 2018), innerhalb derer die einzelnen Merkmale berechnet werden. Um hierbei den Rechenaufwand für das Auffinden der Nachbarpunkte im Hinblick auf die vorliegenden dichten Punktwolken zu minimieren, erfolgt die Nachbarsuche mit zunehmendem Suchradius in einer stärker ausgedünnten Punktwolke (HACKEL et al. 2016). Bevor nun im Folgenden auf die verwendeten Merkmale eingegangen wird, sei auf Abb. 2 verwiesen. Hierin erfolgt eine Visualisierung der anhand des RF-Klassifikators ausgewerteten Relevanz der einzelnen Merkmale für dessen Entscheidungen.

Die definierten Nachbarschaften werden insbesondere zur Ableitung geometrischer Merkmale benötigt. Hierzu zählen eigenwertbasierte Merkmale (BECKER et al. 2017), welche die charakteristische Punktverteilung innerhalb der Nachbarschaft beschreiben (jeweils die ersten 8 Säulen einer Nachbarschaft sowie Q_{ES_2} in Abb. 2). Diese werden durch weitere, ebenfalls die Punktverteilung berücksichtigenden Merkmale, jedoch nicht-eigenwertbasierter Natur, wie etwa der Punktdichte (jeweils Säule 9 in Abb. 2) und dem Verhältnis der Punktanzahl zwischen Kugel- und Zylindernachbarschaft gleicher Radien (Q_N), ergänzt. Als extrem aussagekräftig haben sich zusätzlich höhenbasierte Merkmale herausgestellt, wozu die maximale Höhendifferenz und die Varianz der Höhen (CHEHATA et al. 2009) in einer entsprechenden Nachbarschaft zählen (jeweils Säulen 10 und 11 in Abb. 2). Daneben trägt insbesondere das Merkmal der Höhe Δz_{rel} eines Punktes über Grund zu einer eindeutigen Diskrimination der Punktprimitive bei. Weitere geometrische Merkmale können durch die Bestimmung einer robust geschätzten lokalen Ebene in jedem einzelnen Punkt abgeleitet werden (jeweils die letzten 5 Säulen in Abb. 2). Hierzu zählt der Neigungswinkel der Ebene sowie die Varianz desselben in einer gegebenen Nachbarschaft. Ferner wird neben dem Maß der Vertikalität der geschätzten Ebene zusätzlich der Abstand D des jeweiligen Berechnungspunktes von der ausgleichenden Ebene bestimmt. Als besonders effektives Merkmal wird auf Grundlage dieser Distanzen eine robust bestimmte Standardabweichung (Median of Absolute Differences) nach

$$\sigma_{MAD} = \mathrm{med}[\boldsymbol{D}_N - \mathrm{med}(\boldsymbol{D}_N)]$$

in der Umgebung berechnet, welche zur Detektion von Vegetationsflächen dient.

Um neben geometrischen auch radiometrische Merkmale der Punktprimitive, und zwar nicht nur für die MVS-Punktwolke, sondern auch für den LiDAR-Datensatz, zu gewinnen, wurden zeitgleich mit der LiDAR-Punktwolke Schrägluftbilder aufgezeichnet. Im Sinne einer integrierten Prozessierung wird die aufgezeichnete LiDAR-Punktwolke mittels einer aus diesen Aufnahmen erzeugten photogrammetrischen Punktwolke durch Interpolation aus dieser koloriert. Damit können auch für die LiDAR-Punktwolke Farbmerkmale, wie etwa die Farbkomponenten des HSV- Farbraums und deren Mittelung (Säulen 1-3 bzw. 4-27 von \mathbf{x}_{Farbe} in Abb. 2) in den verwendeten Nachbarschaften (BECKER et al. 2017), als äußerst zweckdienliche Merkmale genutzt werden. Zudem wird aus der aus Nadiraufnahmen prozessierten MVS-Punktwolke ein Orthophoto generiert, welches mittels *Segnet* (BADRINARAYANAN et al. 2017) segmentiert wird. Die entsprechenden Label lassen sich dann als weiteres Merkmal orthogonal auf beide Punktwolken projizieren (letzte Säule von \mathbf{x}_{Farbe} in Abb. 2). Im Falle der LiDAR-Daten kann zusätzlich neben der materialabhängigen Reflektanz des ausgesandten Laserpulses auch das Pulsverhältnis im Rahmen der Merkmalsberechnung verwendet werden (\mathbf{x}_{LiDAR}). Abschließend werden im LiDAR-Fall alle 167 Merkmale bzw. im MVS-Fall 165 Merkmale in einem normierten Merkmalsvektor zusammengefasst.



Abb. 2: Relevanz der Merkmale ausgewertet anhand des RF-Klassifikators für den LiDAR-Datensatz bezüglich des Mehrklassenfalls. $\mathbf{x}_{K1} - \mathbf{x}_{K5}$ und $\mathbf{x}_{Z1} - \mathbf{x}_{Z5}$ bezeichnen die für die Kugel- bzw. Zylindernachbarschaften evaluierten geometrischen Merkmale entsprechend verwendeter ansteigender Radien. Die übrigen Merkmalsbezeichnungen sowie entsprechende Erläuterungen sind Kap. 2.2 zu entnehmen.

Für die praktische Merkmalsberechnung wird auf die Software *OPALS* (PFEIFER et al. 2014) zurückgegriffen. Hauptgrund hierfür ist, dass *OPALS* eine effiziente Datenstruktur nutzt und auch nach Möglichkeit sämtliche Vorgänge parallelisiert werden, was eine hohe Prozessierungsgeschwindigkeit zur Folge hat. Daher ist *OPALS* insbesondere für die Verarbeitung großer Datenmengen, wie sie auch im Rahmen dieser Arbeit vorliegen, prädestiniert. Dennoch hat sich die Prozessierung der originalen hochaufgelösten Punktwolken auf einem Rechner mittlerer Ausstattung als extrem zeitintensiv herausgestellt. Daher wurde untersucht, inwieweit sich die Punktdichte auf die Klassifikationsgüte eines RF-Klassifikators auswirkt, indem für unterschiedlich stark unterabgetastete Punktwolken jeweils die Merkmalsberechnung und eine entsprechende Klassifikation durchgeführt wurden. Als Gütemaß wird hierfür auf den Kappa-Koeffizienten κ zurückgegriffen, welcher in Abhängigkeit von der Punktdichte in Abb. 3 visualisiert ist. Hieraus ist ersichtlich, dass



Abb. 3: Einfluss der Punktdichte auf die Klassifikation ausgewertet für die LiDAR-Punktwolke mittels des RF-Klassifikators anhand des Kappa-Koeffizienten *κ*.

mit abnehmendem Punktabstand bzw. mit zunehmender Punktdichte die Klassifikationsgenauigkeit nahezu linear zunimmt. Bezogen auf die Rechenzeit der Merkmale ergibt sich bei Erhöhung der Punktdichte allerdings ein exponentieller Anstieg. Daher wird als Kompromiss zwischen Rechendauer einerseits und Klassifikationsgenauigkeit andererseits eine Unterabtastung auf 30 cm Punktabstand gewählt. Weiterhin zeigt Abb. 3 auf, dass die Rechendauer des RF-Klassifikators im Vergleich zur Dauer der Merkmalsberechnung zwar nahezu vernachlässigbar ist, jedoch auch diese mit zunehmender Punktdichte ansteigt.

2.3 Klassifikation mittels Random Forest und Multi-Branch 1D-CNN

Die Klassifikation erfolgt sowohl für den LiDAR- als auch für den MVS-Datensatz zunächst durch den klassischen RF-Klassifikator (BREIMAN 2001). Vergleichend wird für den LiDAR-Datensatz zusätzlich der unkonventionelle Ansatz eines Multi-Branch 1D-CNN angewandt, welcher analog zum RF Modellwissen in Form von Merkmalen berücksichtigt. Die Architektur desselben wurde GEORGE et al. (2018) nachempfunden, jedoch für den Zweck dieser Arbeit entsprechend angepasst und ist in Abb. 4 visualisiert. Ein wesentlicher Vorteil eines solchen aus Faltungslayern aufgebauten Netzes gegenüber einer aus Fully-Connected-Layern bestehenden Architektur, mit welcher Beziehungen zwischen benachbarten, aber unkorrelierten Pixeln bzw. Merkmalen verhindert werden können, liegt insbesondere in einer deutlichen Reduktion des Trainingsaufwandes.

Da CNNs hauptsächlich auf die Verwendung im Bildbereich ausgelegt sind, könnte der für jeden Punkt vorliegende eindimensionale Merkmalsvektor jeweils in ein zweidimensionales Bild umgeformt werden und in dieser Form in das CNN eingehen. Um jedoch dabei eben solche durch die Faltungslayer implizierte Beziehungen zwischen benachbarten Merkmalen zu minimieren, schlagen GEORGE et al. (2018) die Nutzung eben jenes eindimensionalen CNNs vor. Die Grundidee der Verwendung mehrerer Äste in der Architektur dieses Multi-Branch 1D-CNN liegt im unabhängigen Training der Teilmerkmalsvektoren unterschiedlicher Skalen in den gegebenen Ästen. Die Dreiländertagung der DGPF, der OVG und der SGPF in Wien, Österreich – Publikationen der DGPF, Band 28, 2019



Abb. 4: Netzarchitektur des Multi-Branch 1D-CNN (nach GEORGE et al. (2018)). Der ursprüngliche LiDAR-Merkmalsvektor wird auf Grundlage des jeweiligen Nachbarschaftsradius in mehrere Teilmerkmalsvektoren zerlegt und jeweils durch die punktweise berechenbaren Merkmale ergänzt. Diese gehen in mehrere aus Faltungslayern, Batch-Normalisierungen, Leaky-ReLU-Aktivierungsfunktionen und Max-Pooling-Layern bestehende Branches ein. Deren Ergebnis wird anschließend zusammengefasst. Die nun deutlich reduzierte Datenmenge kann dann in einen Fully-Connected-Layer einfließen, um unter nochmaliger Nutzung eines solchen Layers das Klassenlabel zu prädizieren.

prozessierten Teilmerkmalsvektoren werden erst anschließend zur Übergabe an die Fully-Connected-Layer und zum Erhalt der Klassenlabel kombiniert. Ein solcher Teilmerkmalsvektor enthält dabei neben den Merkmalen, die speziell für eine Nachbarschaft des entsprechenden Radius evaluiert worden sind, auch jeweils diejenigen Merkmale, die unabhängig von einer Nachbarschaft sind und punktweise berechnet werden können.

2.4 Analyse der Ergebnisse

Für den LiDAR-Datensatz konnte unter Nutzung des RF-Klassifikators mittels optimierter Hyperparameter (300 Entscheidungsbäume der Tiefe 18, minimale Sampleanzahl von 7 für einen neuen Entscheidungstest) und integrierter Merkmalsberechnung mit einer Overall Accuracy (OA) von 86,80% (vgl. Tab. 1) das beste Klassifikationsergebnis erzielt werden. Die zugehörige, bezüglich der Referenzdaten normierte Konfusionsmatrix ist in Abb. 5 dargestellt, wobei im Folgenden auf die größten Fehlzuordnungen exemplarisch eingegangen werden soll.

Der mit 40% höchste Grad der Verwechslung ergibt sich durch die Zuordnung von offenem Boden/Geröll zu *Niedrige Vegetation*. Begründet ist dieser Effekt durch ähnliche relative Höhen und nahezu identische Geometrien. Auch das Hinzuziehen von Farbinformationen kann hier, bedingt durch Überschneidungen in der bräunlichen Farbgebung zwischen offenem Boden und Bereichen dünner Begrasung, keine Klassifikationsverbesserung bewirken. Verstärkt wird dieser Effekt durch den Zeitpunkt der Befliegung Mitte März, da zu dieser Jahreszeit Vegetationsflächen noch nicht durch ihre typische grüne Farbe gekennzeichnet sind. Ferner werden 26% der Punkte, welche tatsächlich Fahrzeuge repräsentieren, fälschlicherweise als *Sonstige Ausstattung* interpretiert. Verursacht wird dies insbesondere durch die Vielfalt innerhalb dieser Klasse, welche eine Fülle unterschiedlicher Farben und Geometrien beinhaltet. Dies erschwert eine Abgrenzung zur Klasse *Fahrzeug*, welche ebenfalls durch große Farbvariationen geprägt ist und deren Vertreter auch bezüglich der relativen Höhen denjenigen der Klasse *Sonstige Ausstattung* ähneln. Weitere Verwechslungen aufgrund jeweils ähnlicher Geometrien und Farbgebung treten erwartungsgemäß zwischen *Fassade* und *Vertikale Fläche* sowie zwischen *Strauch/Hecke* und *Baum* auf.

Das erhaltene Klassifikationsergebnis wird zusätzlich in Abb. 6 graphisch den Referenzdaten gegenübergestellt, woraus eine weitgehende Übereinstimmung erkennbar ist. Abweichungen fallen insbesondere anhand der Baustelle im unteren Bereich auf, wobei sich hier das Klassifikationsergebnis in Teilen von der tatsächlichen Klasse *Offener Boden/Geröll* unterscheidet. Weiterhin zeigen sich auch Fehlzuordnungen von Zäunen, welche oft fälschlicherweise als *Strauch/Hecke* klassifiziert werden. Dies ist insofern nachvollziehbar, als beispielsweise eine Weinrebe, welche per Definition als *Strauch/Hecke* gilt, oft nur schwerlich von einem leicht überwucherten Zaun zu trennen ist.

Dieses Klassifikationsergebnis fällt insgesamt trotz höherer Klassenanzahl und damit anspruchsvollerer Klassifikationsaufgabe besser aus als das beste Ergebnis für den ISPRS Benchmark Datensatz Vaihingen/Enz (ZHAO et al. 2018). Da für diesen jedoch keine gleichzeitig erfassten Bilddaten vorliegen, kann eine Anwendung der vorgestellten Methodik auf diesen Datensatz zum direkten Vergleich nicht erfolgen.

				Koi	ntusi	onsr	natr	ix, n	ormi	.00 0.00 0.00 0.0				
	Stromleitung -	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00		
Klassen aus Klassifikation	Niedrige Vegetation -	0.00	0.96	0.08	0.03	0.07	0.00	0.02	0.07	0.00	0.40	0.02		
	Versiegelte Fläche -	0.00	0.01	0.86	0.04	0.01	0.03	0.01	0.00	0.00	0.15	0.05		
	Fahrzeug -	0.00	0.00	0.00	0.51	0.01	0.00	0.00	0.00	0.00	0.00	0.00		
	Sonstige Ausstattung -	0.00	0.00	0.00	0.26	0.35	0.00	0.03	0.01	0.00	0.00	0.02		
	Dach -	0.00	0.00	0.02	0.02	0.08	0.92	0.05	0.00	0.00	0.00	0.01		
	Fassade -	0.00	0.00	0.01	0.02	0.14	0.02	0.84	0.01	0.00	0.00	0.16		
	Strauch/Hecke -	0.00	0.01	0.00	0.07	0.17	0.00	0.01	0.70	0.00	0.00	0.00		
	Baum -	0.00	0.01	0.00	0.04	0.11	0.03	0.03	0.21	0.99	0.00	0.00		
	Offener Boden/Geröll -	0.00	0.01	0.02	0.00	0.00	0.00	0.00	0.00	0.00	0.44	0.01		
	Vertikale Fläche -	0.00	0.00	0.00	0.01	0.04	0.00	0.02	0.00	0.00	0.00	0.74		
		Stromleitung -	Niedrige Vegetation -	Versiegelte Fläche -	Fahrzeug -	Sonstige Ausstattung -	Dach -	Fassade -	- Strauch/Hecke -	Baum -	Offener Boden/Geröll -	Vertikale Fläche -		
			Klassen aus Referenzdaten											

Abb. 5: Darstellung des Klassifikationsergebnisses des RF-Klassifikators für den LiDAR-Datensatz bezüglich des Mehrklassenfalls anhand der normierten Konfusionsmatrix.

Dreiländertagung der DGPF, der OVG und der SGPF in Wien, Österreich - Publikationen der DGPF, Band 28, 2019



Abb. 6: Vergleich des Klassifikationsergebnisses des RF-Klassifikators für den LiDAR-Datensatz (unten) mit Referenzdaten (oben) bzgl. des Mehrklassenfalls. (0=Stromleitung, 1=Niedrige Vegetation, 2=Versiegelte Fläche, 3=Fahrzeug, 4=Sonstige Ausstattung, 5=Dach, 6=Fassade, 7=Strauch/Hecke, 8=Baum, 9=Offener Boden/Geröll, 10=Vertikale Fläche). Insbesondere die Klassen Dach, Versiegelte Fläche, Baum und Stromleitung werden detektiert. Die Klasse Offener Boden/Geröll wird oft nicht oder nur in Teilen erkannt. Eine alternative Klassifikation mittels des in 2.3 vorgestellten Ansatzes des Multi-Branch 1D-CNN erreicht nur eine geringfügig schlechtere OA von 84,67% (vgl. Tab. 1).

	Randor	n Forest	Multi-Branch 1D-CNN			
Klassenbezeichnung	PA [%]	UA [%]	PA [%]	UA [%]		
Stromleitung	100	100	98,10(-1,90)	96,27(-3,73)		
Niedrige Vegetation	96,37	85,00	94,22(-2,15)	85,01(+0,01)		
Versiegelte Fläche	86,26	90,03	78,31(-7,95)	89,21(-0,79)		
Fahrzeug	51,31	88,39	64,87(+13,56)	66,55(-21,84)		
Sonstige Ausstattung	35,12	68,39	43,54(+8,42)	55,98(-12,41)		
Dach	91,60	87,49	92,23(+0,63)	81,50(-5,99)		
Fassade	83,89	81,59	80,71(-3,18)	80,97(-0,62)		
Strauch/Hecke	69,54	69,56	73,99(+4,45)	60,58(-8,98)		
Baum	99,15	92,69	97,06(-2,09)	95,63(+2,94)		
Offener Boden/Geröll	44,48	79,73	37,51(-6,97)	65,74(-13,99)		
Vertikale Fläche	73,74	85,70	73,16(-0,58)	76,28(-9,42)		
OA [%]	86	,80	84,67(-2,13)			

Tab. 1: Vergleich der Genauigkeitsmaße des RF-Klassifikators mit dem Multi-Branch 1D-CNN-Klassifikator für den LiDAR-Datensatz bzgl. des Mehrklassenfalls (PA=Producer's Accuracy, UA=User's Accuracy).

Die Ursache für das beim Multi-Branch 1D-CNN bessere Ergebnis für die Producer's Accuracy (PA) insbesondere in Bezug auf die Klassen *Fahrzeug*, *Sonstige Ausstattung* und *Strauch/Hecke* (vgl. Tab. 1) liegt darin, dass an die Loss-Funktion eine Gewichtung bezüglich der einzelnen Klassen angebracht wird, mit dem Ziel, schwach vertretene Klassen im Rahmen des Trainings stärker zu berücksichtigen. Konkret wird die Gewichtung für jede Klasse aus der Inversen der Wurzel aus den relativen Häufigkeiten der Klassen in den Trainingsdaten abgeleitet.

Die Klassifikation des MVS-Datensatzes mittels RF fällt mit einer OA von 81,60% etwas schlechter aus, da diese Punktwolke aufgrund von Verdeckungen und erschwertem Matching in Vegetationsbereichen von einer im Vergleich zum LiDAR-Datensatz unvollständigeren Geometrie gekennzeichnet ist.

Für die zu Monitoringzwecken ausreichende binäre Klassifikation konnte durch erneutes Trainieren auf binären Referenzdaten für den LiDAR-Datensatz mittels RF mit einer OA von 95,71% das beabsichtigte Ziel der Detektion von festen, nicht-vertikalen Flächen erreicht werden. Die so aufgefundenen Flächen gehen mit einer Zuverlässigkeit von 94,23% in das Deformationsmodell ein.

3 Fazit & Ausblick

Im Rahmen der Klassifikation hat sich die gleichzeitige Verfügbarkeit von Bild- und LiDAR-Daten für eine integrierte Merkmalsextraktion als vorteilhaft herausgestellt, sodass das Ziel der Detektion von für Monitoringzwecke geeigneten Flächen erreicht werden konnte. Als Klassifikator mit bereits sehr guter Genauigkeit hat sich zudem das Multi-Branch 1D-CNN erwiesen, wenngleich dieses vom RF noch übertroffen wird. Nachteil des CNN-Klassifikators ist jedoch das für diesen Klassifikatortyp typische Erfordernis einer großen Menge an Trainingsdaten, welche durch die vorliegenden hochaufgelösten Punktwolken zwar gestellt werden, mittels derzeit verfügbarer Implementierungen und Hardware jedoch noch nicht ohne erheblichen Zeitaufwand ausgenutzt werden kann. Wenn dieses Problem noch bewältigt werden kann, hat dieser Klassifikator das Potential, den genutzten RF im Hinblick auf die Genauigkeit zu übertreffen. In Bezug auf das im Rahmen dieser Arbeit vorgestellte Monitoringprojekt soll zudem künftig untersucht werden, in-wieweit der auf den Daten der ersten Epoche basierende Klassifikator auf Daten anderer Epochen abweichender Jahreszeiten anwendbar ist.

4 Literaturverzeichnis

- AGISOFT PHOTOSCAN, 2018: PhotoScan photogrammetric processing of digital images and 3D spatial data generation. Website. (http://www.agisoft.com/; letzter Zugriff 27.11.2018)
- BADRINARAYANAN, V., KENDALL, A. & CIPPOLLA, R., 2017: SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39(12), 2481-2495.
- BECKER, C., HÄNI, N., ROSINSKAYA, E., D'ANGELO, E. & STRECHA, C., 2017: Classification of Aerial Photogrammetric 3D Point Clouds. ISPRS Ann. Photogr. Rem. Sens. Spat. Inf. Sci., IV-1/W1, 3-10.
- BREIMAN, L., 2001: Random Forests. Journal of Machine Learning, 45(1), 5-32.
- CHEHATA, N., GUO, L. & MALLET, C., 2009: Airborne LiDAR feature selection for urban classification using random forests. Int. Arch. Photogr. Rem. Sens. and Spat. Inf. Sci., **38**(3/W8), 207-212.
- CRAMER, M., HAALA, N., LAUPHEIMER, D., MANDLBURGER, G. & HAVEL, P., 2018: Ultra-High Precision UAV-based LiDAR and Dense Image Matching. Int. Arch. Photogr. Rem. Sens. Spat. Inf. Sci., **42**(1), 115-120.
- GEORGE, D., XIE, X. & TAM, G., 2018: 3D Mesh Segmentation via Multi-branch 1D Convolutional Neural Networks. Graphical Models, **96**, 1-10.
- HACKEL, T., WEGNER, J. & SCHINDLER, K., 2016: Fast semantic segmentation of 3D point clouds with strongly varying density. ISPRS Ann. Photogr. Rem. Sens. Spat. Inf. Sci., III-3, 177-184.
- NIEMEYER, J., ROTTENSTEINER, F. & SÖRGEL, U., 2014: Contextual classification of LiDAR data and building object detection in urban areas. ISPRS Jour. Photogr. Rem. Sens., 87, 152-165.
- PFEIFER, N., MANDLBURGER, G., OTEPKA, J. & KAREL, W., 2014: OPALS A framework for Airborne Laser Scanning data analysis. Comp. Environ. Urban Sys., **45**, 125-136.
- WEINMANN, M., BLOMLEY, R., WEINMANN, M. & JUTZI, B., 2018: Investigations on the Potential of Binary and Multi-class Classification for Object Extraction from Airborne Laser Scanning Point Clouds. Tagungsband der 38. Wissensch.-Tech. Jahrestagung der DGPF, 27, 408-421.
- ZHAO, R., PANG, M. & WANG, J., 2018: Classifying airborne LiDAR point clouds via deep features learned by a multi-scale convolutional neural network. Int. Jour. Geo. Inf. Sci., 32(5), 960-979.