

Automatisierte Erkennung von Baumkronen in urbanen Gebieten mittels Fernerkundungsdaten

Max Rein, Elias Naber, Rebekka Volk, Frank Schultmann

Zusammenfassung

Die Auswirkungen des Klimawandels und der damit verbundene Handlungsdruck stellen Kommunen vor große Herausforderungen. Versiegelte Flächen und fehlende Begrünung beeinträchtigen Mikroklima und Luftqualität negativ. Stadtbäume können wesentlich zur Verbesserung beitragen und spielen daher eine zentrale Rolle in der nachhaltigen Stadtentwicklung. Eine wesentliche Grundlage zur Bewertung von Begrünungspotenzialen bilden aufwändig erhobene Baumkataster. Diese erfassen meist nur Bäume im öffentlichen Raum, während Bäume auf Privatgrundstücken oft unberücksichtigt bleiben. Die flächendeckende, automatisierte Erfassung von Stadtbäumen mittels Fernerkundung ist daher ein aktuelles Forschungsthema. In diesem Beitrag wird ein Baumerkennungsverfahren, das auf LiDAR-Daten, Orthofotos und 3D-Gebäudemodellen basiert, weiterentwickelt und evaluiert. Durch den Einsatz von maschinellem Lernen wurden neue Funktionen für variable Suchfenstergrößen entwickelt, mit denen potenzielle Baumspitzen aus dem Kronenhöhenmodell extrahiert werden. Die Erweiterungen und die Evaluation der Methode erfolgten in einem Testgebiet in Köln mit 1.683 manuell erfassten Bäumen. Die Güte der Methode wurde anhand stichprobenunabhängiger Metriken bewertet. Insgesamt konnte die Genauigkeit der automatischen Baumkronenerkennung sowie die Schätzung des darin gespeicherten CO₂ auf Siedlungs- und Verkehrsflächen verbessert werden. Dennoch besteht weiterer Forschungs- und Entwicklungsbedarf in der automatisierten und exakten Baumerkennung.

Schlagnworte: Baumerkennung, Automatisierung, LiDAR, Orthofotos, 3D-Gebäudemodelle

1 Einführung

Die Auswirkungen des Klimawandels und der damit verbundene Temperaturanstieg stellen Städte vor neue Herausforderungen. Der Rückgang der biologischen Vielfalt sowie die zunehmende Versiegelung sind Faktoren, die zu einer Verschlechterung der Luftqualität und zur Bildung von urbanen Hitzeinseln beitragen. Die Relevanz der Förderung nachhaltiger Entwicklung in Städten wird ebenfalls ersichtlich in den Sustainable Development Goals der UN (SDGs). Ziel 11 umfasst, „Städte und menschliche Siedlungen integrativ, sicher, widerstandsfähig und nachhaltig zu machen“ (United Nations 2015). Die Verringerung der negativen Pro-Kopf-Umweltauswirkungen von Städten (Ziel 11.6), sowie die damit verbundene Verbesserung der Ressourceneffizienz zur Eindämmung des Klimawandels und Anpassung an diesen

stellen wesentliche Elemente zur Erreichung der genannten Ziele dar. Um diese zu erreichen, ist zunächst eine genaue Erfassung der aktuellen Situation erforderlich, um eine Datenbasis für künftige Pläne und Modelle zu schaffen. Die Verwendung dreidimensionaler Stadtmodelle ermöglicht die Simulation von Wärmeinseleffekten und der Luftqualität in städtischen Gebieten. Eine präzisere Datenbasis ermöglicht detailliertere Simulationen und Modellierungen der Stadtbegrünung, welche bei der Entscheidungsfindung für Stadtplanungs- und Entwicklungsstrategien berücksichtigt werden können (Naber et al. 2022; Volk et al. 2022).

Digitale Orthofotos (DOP), Laser Punktwolkendaten (LiDAR) und 3D-Gebäudemodelle sind deutschlandweit flächendeckend verfügbar. Baumkataster sind nicht in jeder Gemeinde vorhanden und wenn sie vorhanden sind, sind meist die Bäume auf privaten Flurstücken nicht erfasst. Zudem enthalten sie meist keine Informationen zur Baumkronenform und Größe. Die manuelle Vermessung von Bäumen in städtischen Gebieten ist jedoch ein zeitaufwändiger und kostspieliger Prozess. Die automatische Baumerfassung hingegen verspricht durch Kosten- und Zeiteinsparungen eine verbesserte Datenerfassung, Baumüberwachung, sowie die Möglichkeit, auch Bäume auf Privatgrundstücken zu erfassen. Das Ziel des Beitrags ist die Umsetzung, Verbesserung und Evaluation der Güte eines fernerkundungsdaten-basierten Verfahrens zur Baumerkennung anhand öffentlich flächendeckend verfügbarer Daten.

2 Stand der Forschung

Vegetationserkennung mittels Fernerkundungsdaten ist ein etabliertes Forschungsfeld. Die existierenden Ansätze befassen sich einerseits mit flächenbasierten Erhebungen, bei denen z. B. für ein Waldstück festgestellt werden soll, ob eine Durchforstung benötigt wird. Andererseits gibt es Ansätze, bei denen die Eigenschaften einzelner Bäume erfasst werden. Da Stadtbäume in der Regel nicht in homogenen, waldähnlichen Beständen vorliegen, erweisen sich flächenbasierte Ansätze zur Beschreibung von Stadtbäumen als inadäquat. Die Anwendung der einzelbaumbasierten Methoden auf den urbanen Kontext und etwaige Erweiterungen mit dem Ziel nicht erfasste Stadtbäume besser detektieren zu können, stehen im Fokus dieses Beitrags. Hierbei ist für die Erkennung einzelner Bäume die Unterscheidung zwischen den Baumkronen ein zentraler Aspekt. Für Mischwälder in New York State verwenden Liu et al. (2015) einen sog. Watershed-Segmentation-Ansatz, um aus dem Kronenhöhenmodell (Canopy Height Model, CHM) einzelne Baumkronen zu segmentieren. Sie nutzen den Fishing-Net-Dragging-Ansatz (FIND), um eine zu kleinteilige Segmentierung zu vermeiden und kleine Segmente den jeweils nächstgelegenen größeren Segmenten zuzuordnen. Ein Random-Forest-Verfahren klassifiziert die Grenzsegmente, um zwischen Ästen desselben Baums und verschiedenen Bäumen zu unterscheiden. Im Gegensatz hierzu stellen Sačkov et. al. (2017) einen Ansatz vor, der Einzelbäume, identifiziert über ihre Baumspitzen, mittels eines auf Allometrie basierenden Geo-Dendrometrie-Tests in slowakischen Mischwäldern voneinander unterscheidet. Allometrische Tests nutzen die Beziehung zwischen Größe und Form des Baums, um

Schlussfolgerungen zu ziehen, während die Dendrometrie sich mit der Messung der verschiedenen Dimensionen von Bäumen befasst. Sačkov et. al. (2017) verwenden einen lokalen Maximumfilter mit variabler Fenstergröße, um potenzielle Baumspitzen, repräsentiert durch die lokalen Maxima, zu identifizieren. Diese Baumspitz-Kandidaten werden mittels Geo-dendromentrischer Tests, welche unter anderem die Höhenbeziehungen zwischen benachbarten Bäumen und das Verhältnis zwischen Baumhöhe und Kronenparametern enthalten, in echte und falsche Baumspitzen unterteilt. Die echten Baumspitzen werden als Mittelpunkt eines Kreises, welcher das zentrale Kronensegment abbildet, dargestellt. Ausgehend von diesen zentralen Kronensegmenten werden schrittweise die Punkte der Punktwolke dem jeweils nächstgelegenen Kronensegment zugeordnet, bis Punkte erreicht werden, die bereits einem anderen Kronensegment zugeordnet sind oder eine maximale Kronengröße, einstellbar über die maximale Anzahl an zugeordneten Punkten je Segment, erreicht wird. Der Ansatz liefert als Ergebnis 2D-Kronenprojektionen der gefundenen Einzelbäume.

Eine Kombination der zwei Ansätze findet sich im Ansatz von Münzinger et. al. (2022), welcher die Watershed-Segmentierung des Kronenhöhenmodells von Liu et. al. (2015) mit der auf variablen Fensterfunktionen basierenden Baumspitzdetektion von Sačkov et. al. (2017) kombiniert. Hierbei werden die Baumspitzen mittels der variablen Fensterfunktion für europäische Mischwälder von Popescu und Wynne (2004) bestimmt und als Marker der anschließenden Marker-Controlled-Watershed-Segmentation verwendet. Dies führt zu einer Reduktion in der Anzahl der übersegmentierten Bäume, wodurch die FiND-Nachbearbeitung von Liu et. al. (2015) nicht mehr benötigt wird. Implementiert wurde der Ansatz in R unter Verwendung des lidR Pakets (Jean-Romain Roussel et al. 2020).

Evaluiert werden meist die von Bäumen überdeckte Fläche, die Einzelbaumerkennung und die Baumkronenerkennung (Tabelle 1). Aus pixel- oder segmentweise annotierten Kronenhöhenmodellen lässt sich die von Bäumen überdeckte Fläche extrahieren. Für die Evaluation kommen meist Binärmasken zum Einsatz. Zur Erstellung der Binärmaske wird händisch jedes Pixel als Baum oder Nicht-Baum klassifiziert. Das annotierte Kronenhöhenmodell wird mit dieser Binärmaske abgeglichen. Die Anzahl an Baumpixel, welche als Baum detektiert wurden, bilden die True-Positive-Fälle, während Baumpixel, die nicht als Baum erkannt wurden, die False-Negative-Fälle bilden. Nicht-Baum-Pixel, welche als Baum erkannt worden sind, False-Positive-Fälle und Nicht-Baum-Pixel, welche als Nicht-Baum erkannt wurden, sind True-Negative-Fälle. Hieraus werden die Metriken Korrektklassifikationsrate (Accuracy), Relevanz (Precision), Sensitivität (Recall) und F-Maß (F1-Score) berechnet.

Tabelle 1: Überblick über die in der Literatur verwendeten Evaluationsmetriken

Ziel	Evaluationsmethodik	Quelle
Erfassung der belaubten Fläche	Vergleich von klassifiziertem CHM mit händisch erstellter Binärmaske	Münzinger et. al. (2022), Ponce et. al. (2021), Schmohl et. al. (2022), Yang et. al. (2009)
	Händischer Abgleich mit Orthofotos	Ozdarici-Ok und Ok (2023)
Einzelbaum-erkennung	Händische Auswertung	Münzinger et. al. (2022)
	Auswertung mittels Stammposition aus Erhebungsdaten	Weinstein et. al. (2021)
	Höhenbasierte Auswertung innerhalb der detektierten Baumkrone	Dalponte et. al. (2016)
	Höhenbasierte Auswertung mit variablem Fehlermaß	Xu et. al. (2023)
Baumkronen-erkennung	Händische Zuordnung in über-, unter- und korrekt segmentiert	Münzinger et. al. (2022)
	Vergleich mit händisch segmentierten Baumkronen	Heinzel et. al. (2011)
	IoU-basierte Auswertung mittels Binärmaske	Ponce et. al. (2021)
	IoU basierte Auswertung mittels Kronenpolygonen und Bounding box	Schmohl et. al. (2022), Weinstein et. al. (2021)

Die Evaluation der Einzelbaumerkennung findet wie z. B. bei Münzinger et. al. (2022), Li et. al. (2012) und Ozdarici-Ok und Ok (2023) meist händisch statt. Automatisierte Evaluationen finden sich in Dalponte et. al. (2016), welche die Erhebungsbäume über die Höhendifferenz innerhalb der detektierten Baumkrone zuordnen. Liegt innerhalb einer detektierten Baumkrone nur ein realer Baum gemäß der Erhebungsdaten, so gilt dieser als korrekt erkannt. Liegen mehrere reale Bäume innerhalb einer detektierten Baumkrone, so gilt der reale Baum im Erhebungsdatensatz mit der kleinsten Höhendifferenz zum detektierten Baum als korrekt erkannt, die restlichen werden als Fehldetektion klassifiziert. Eine Erweiterung dieses Ansatzes findet sich in Xu et. al. (2023). Hier werden Stammdistanz und Höhendifferenzklassen eingeführt. Je höher der detektierte Baum, desto größer ist die erlaubte Abweichung. Detektierte Bäume werden der Größe nach absteigend den Erhebungsbäumen zugeordnet. Sollten sich innerhalb der erlaubten Abweichung um den detektierten Baum mehrere Erhebungsbäume befinden, so wird derjenige gewählt, welcher die kleinste Abweichung aufweist.

Die Evaluation der Baumkronenerkennung findet ebenfalls meist händisch statt. Ansätze zur automatisierten Evaluation finden sich in Schmohl et. al. (2022) und Weinstein et. al. (2021). Beide verwenden die Intersection over Union (IoU) Metrik. Während Schmohl et. al. (2022) händisch erzeugte kreisförmige Polygone verwendet, werden bei Weinstein (2021) rechteckige Bounding Boxen aus bildbasierter

händischer Annotation und bei der Baumvermessung mittels Tablets aufgezeichnete Polygone verwendet. Schmohl et. al. (2022) verwenden IoU-Schwellenwerte von 0,3 bis 0,7 während Weinstein et. al. (2021) sich für einen Schwellenwert von 0,4 entschieden haben.

Anhand der vielen verschiedenen Evaluationsmethoden ist ein Vergleich der Modellgüte zwischen den Ansätzen schwierig. Xu et. al. (2023) wenden ihre Evaluationsmethodik auf die Ansätze von Li et. al. (2012), Dalponte et. al. (2016), Silva et. al. (2016) und einen generischen Watershed-Ansatz an, um die Modellgüte vergleichen zu können.

Basierend auf dem Literaturüberblick erscheint eine Weiterentwicklung der Baumerkennung unter Verwendung flächennutzungsartangepasster variabler Fensterfunktion vielversprechend und wird im Folgenden weiterverfolgt. Für die Evaluierung und den Vergleich der Ergebnisse werden übertragbare und stichprobenunabhängige Metriken gewählt.

3 Methodik

Als Ausgangspunkt für die Baumerkennung im urbanen Kontext wurde der Ansatz von Münzinger et. al. (2022) implementiert und unter Verwendung des lidR Pakets¹ (Jean-Romain Roussel et al. 2020) um flächennutzungsartbasierte Fensterfunktionen, eine automatisierte Evaluationsmetrik und eine Berechnung des CO₂ Bestands ergänzt. Das Untersuchungsgebiet im Kölner Stadtteil Weidenpesch umfasst 45,8 Hektar. Es enthält neben Wohngebieten auch den Weidenpescher Park. Abbildung 1 zeigt die Unterteilung in Gebäude- und Freiflächen: Wohnen, Verkehrsflächen und Erholungsflächen. Die Datengrundlage bildet eine vollständige Baumkartierung von Krehl et. al. (2023, unveröffentlicht) im Rahmen des Forschungsprojekts Namarés 2.0². Verwendet wurden die von Geobasis NRW bereitgestellten DOP³.

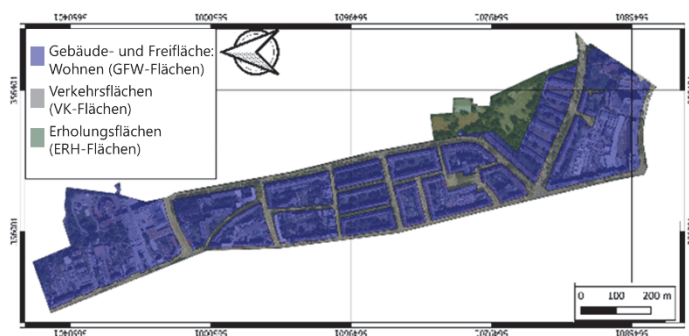


Abb. 1: Eigene Darstellung, Kartengrundlage Stadt Köln, DOP bereitgestellt von Geobasis NRW³

¹ <https://r-lidar.github.io/lidRbook/>

² https://ressourceneffiziente-stadtquartiere.de/?page_id=6633

³ <https://www.opengeodata.nrw.de/produkte/geobasis/lusat/akt/dop>, abgerufen am 31.05.2024

3.1 Angepasste Datenvorverarbeitung

Für eine optimale Baumerkennung befasst sich die Datenvorverarbeitung damit, möglichst viele Datenpunkte, welche keine Vegetation enthalten, aus den Rohdaten zu entfernen. In einem ersten Schritt werden aus der LiDAR-Punktwolke die Bodenpunkte von den Oberflächenpunkten getrennt. Aus den Bodenpunkten wird mittels Delaunay-Triangulierung ein Digitales Terrain Modell (DTM) erstellt. Aus den Oberflächenpunkten werden nun die Gebäude mittels der Dachpunkte im LOD2-Stadtmodell extrahiert. In der verbleibenden LiDAR-Punktwolke werden alle Punkte, die unterhalb der Dachpunkte eines Gebäudes liegen, entfernt. Zudem werden die Punkte innerhalb eines Höhenpuffers von 3m um die Dachpunkte ebenfalls entfernt, da das LOD2-Stadtmodell⁴ eine Höhengenaugigkeit von ± 1 m aufweist. Bei komplexen Dachformen sind grobe Abweichungen möglich. Um weitere Nicht-Baum-Objekte aus der Punktwolke zu entfernen, wird die Annahme getroffen, dass Objekte mit planaren Flächen, wie zum Beispiel Gartenzäune und Dächer von Gartenhütten, keine Bäume sind. Mit den Algorithmen von Limberger und Oliviera (2015) wurden daher sowohl koplanare Punkte als auch Punkte, welche einen Linienzug bilden, detektiert und aus der Punktwolke entfernt. Die resultierende Punktwolke wird mithilfe des DTM höhen-normalisiert und ein normalisiertes digitales Oberflächenmodell (nDOM) berechnet. Alle Punkte außerhalb des Bereichs von 3m bis 40m werden dabei entfernt. Diese Grenzwerte wurden so gewählt, dass der höchste und der niedrigste Baum aus den manuellen Erhebungsdaten noch in der Punktwolke enthalten bleiben. Das nDOM wird mittels Watershed-Segmentation segmentiert und die Segmente mithilfe eines „Baumkriteriums“ klassifiziert:

$$\text{Baumkriterium} = \text{meanNOR} + \text{IPQ} + \text{meanNDVI} = \begin{cases} \geq 0,55, & \text{Baum} \\ < 0,55, & \text{kein Baum} \end{cases}$$

Hierfür werden die digitalen Orthofotos über den Normalized Difference Vegetation Index (NDVI), welcher pixelweise berechnet wurde, zu einer Karte der Vegetationsbedeckung reduziert und verwendet, um für jedes Segment des nDOM den durchschnittlichen NDVI (*meanNDVI*) zu berechnen. Zudem wird für die Segmente die durchschnittliche Anzahl an lokalen Maxima der Laser-Wellenformkurve, sog. LiDAR returns (*meanNOR*), gewichtet nach der Segmentgröße, und der Isoperimetrische Quotient (*IPQ*), welcher das Verhältnis zwischen Umfang der Fläche und dem eingeschlossenen Flächeninhalt darstellt, berechnet. Erreicht ein Segment nicht den Schwellenwert des „Baumkriteriums“ wird es entfernt. Als letzter Schritt wird ein Kronenhöhenmodell (CHM) aus den verbliebenen Segmenten erstellt und als Maske über die LiDAR-Punktwolke gelegt, um alle Punkte, welche in Segmenten ohne Vegetation liegen, zu entfernen.

⁴ <https://www.bezreg-koeln.nrw.de/geobasis-nrw/produkte-und-dienste/3d-gebaeudemodelle>

3.2 Einzelbaumerkennung mit variablem Suchfenster

Für die Detektion der einzelnen Bäume aus dem CHM wird ein Marker-Controlled-Watershed-Segmentation (MCWS) Algorithmus⁵ verwendet. Hierbei wird das CHM invertiert und ausgehend von den Markern simulativ mit Wasser befüllt, bis sich die Wasserflächen treffen. Die aus den Wasserflächen extrahierten Segmente stellen die einzelnen Baumkronen dar. Identifiziert wird ein Baum über seine Baumspitze, welche den Marker für die MCWS darstellt. Die Baumspitz-Kandidaten werden mittels eines lokalen Maximum-Filters mit radialem Suchfenster erfasst. Da eine stark positive Korrelation zwischen Baumhöhe und Kronendurchmesser besteht, liefert ein variables Suchfenster, welches seine Größe in Abhängigkeit der Baumhöhe anpasst, bessere Ergebnisse als eine statische Fenstergröße. Bisher werden meist Suchfensterfunktionen aus der Literatur verwendet. Münzinger et. al verwenden z. B. die Funktion von Popescu und Wynne (2004), welche für europäische Mischwälder erstellt wurde. Um den besonderen Gegebenheiten im urbanen Kontext Rechnung zu tragen, wurden in diesem Beitrag aus den manuellen Erhebungsdaten mittels linearer Regression, Support Vektor Regression (SVR) und Generalized-Additive-Model-Regression (GAM) neue Fensterfunktionen errechnet. Dies beruht auf der Annahme, dass Stadtbäume andere Wachstumseigenschaften besitzen als Waldbäume und dass diese Eigenschaften sich je nach Flächennutzung unterscheiden. Bäume auf öffentlichem Grund werden z. B. von der Stadt nach genauen Vorgaben beschnitten und stehen auf Verkehrsflächen, d. h. zum Beispiel entlang von Straßen oder auf Parkplätzen, meist weniger dicht als im Wald. Unter der Annahme, dass die Beziehung zwischen Kronengröße und Baumhöhe je nach Flächennutzungsart - eingeteilt in Verkehrsflächen (VK), Erholungsflächen (ERH), Gebäude und Freiflächen Wohnen (GFW) - voneinander abweicht, wurden flächennutzungsartabhängige und -unabhängige Fensterfunktionen errechnet. Somit wurden jedes der drei Verfahren sowohl auf die Daten der einzelnen Flächennutzungsarten als auch auf die Gesamtheit angewendet. Ein Vergleich ausgewählter Fensterfunktionen mit der Referenzfunktion von Popescu und Wynne (2004) in Abbildung 2 zeigt, dass die Referenzfunktion bis zu einer Baumhöhe von ca. 31 m die urbane Baumkronengröße unterschätzt. Zudem wird ersichtlich, dass die Kronengröße der Bäume auf GFW- und VK-Flächen ab einer Höhe von ca. 27 m abnimmt und damit stark von der Kronengröße der Bäume auf ERH-Flächen abweicht.

Die hieraus entstandenen Watershed-Segmente werden nochmals mittels des oben genannten Baumkriteriums klassifiziert und jedem gefundenen Baum ein eindeutiger Identifier zugewiesen. Anschließend werden sämtliche Punkte der LiDAR-Punktwolke, welche in einem Baumsegment liegen, extrahiert. Es wird die Baumkrone als 2D- und 3D-konvexe Hülle berechnet und alle Baumkronen mit einer Kronenfläche

⁵ <https://www.mathworks.com/help/images/marker-controlled-watershed-segmentation.html>




Abb. 2: Vergleich der Referenzfunktion Popescu und Wynne (2004) (rosa) mit flächennutzungs-artbezogenen SVR-Funktionen.

von kleiner als 1m^2 und einem Kronenvolumen von weniger als $1,5\text{m}^3$ aus dem Datensatz entfernt. Die Stammposition wird über den Mittelpunkt des Kronenpolygons bestimmt.

Jeder Stamm bekommt mithilfe des DTM eine Bodenhöhe zugewiesen und die Höhe des Baums wird über die Differenz zwischen dem höchsten Punkt und der Bodenhöhe bestimmt. Der Kronendurchmesser wird als Mittelwert der Höhe und Länge des Kronenpolygons bestimmt. Das Kronenvolumen errechnet sich aus dem Volumen der 3D-konvexen Hülle.

3.3 Berechnung des gespeicherten CO_2 im Baumbestand

Der gängige Ansatz zur Berechnung des gespeicherten CO_2 im Baumbestand ist die Berechnung der Biomasse der Bäume, welche mit 0,5 multipliziert wird, um die Masse an enthaltenem Kohlenstoff zu bestimmen. Mithilfe der molaren Masse von Kohlenstoff und Sauerstoff lässt sich die Masse an CO_2 bestimmen (Kändler et al. 2011; Xu et al. 2021).

Zentraler Punkt bei der CO_2 -Bestimmung ist die Berechnung der Baumbiomasse. Hierzu gibt es in der Literatur etliche Ansätze, welche zumeist auf den Messgrößen Brusthöhendurchmesser (*bhd*) und Baumhöhe (*h*) beruhen (Dalponte et al. 2016). Während der *bhd* und die Baumhöhe im Feld gut zu erfassen sind, ist besonders der *bhd* fernerkundlich nur sehr ungenau erfassbar. Ansätze, welche den *bhd* mittels Regression aus der Baumhöhe und Kronenparametern schätzen, z. B. Gülçin und van den Bosch (2021), leiden im Untersuchungsgebiet unter niedriger Genauigkeit, da der Baumbestand stark heterogen ist. So existieren Bäume mit gleichem *bhd* und ähnlicher Höhe, welche jedoch um den Faktor 3 voneinander abweichende Kronenmaße besitzen. Um dieser besonderen Gegebenheit Rechnung zu tragen, hat das Forstliche Bildungszentrum Karlsruhe anhand von Stadtbäumen in Karlsruhe eine Methodik entwickelt, die Biomasse direkt aus fernerkundlich gemessenen Baumhöhen und Kronenflächen zu bestimmen (Kändler et al. 2011). Mithilfe dieser Berechnungsfunktion

wurde aus den Erhebungsdaten ein Basis-Biomassewert errechnet, welcher mit den mittels der von den verschiedenen Fensterfunktionen detektierten Bäumen errechneten Biomassen verglichen wird. Berechnet wurde die Biomasse aller Bäume innerhalb des Untersuchungsgebietes in Köln Nippes und nach Flächennutzung (VK, GFW und ERH).

3.4 Evaluationsmetriken

Da für das hier betrachtete Untersuchungsgebiet keine Binärmasken existiert, wurde in diesem Beitrag eine Einzelbaumerkennung und die Kronendetektion durchgeführt und evaluiert. Für die Einzelbaumerkennung wurde der Ansatz von Xu et. al. (2023) mit den Schwellenwerten in Tabelle 2 angewendet.

Die Güte der Kronendetektion wird mittels der Intersection over Union (IoU) zwischen den detektierten Baumkronen und den aus den Erhebungsdaten approximierten Baumkronen evaluiert. Da in den Erhebungsdaten keine Angaben zur Kronenform enthalten sind, wurden die Baumkronen als Kreise approximiert. Als IoU-Schwellenwert wurde in Anlehnung an Schmohl et al. (2022) 0,3 angenommen. Der Schwellenwert wurde bewusst klein gewählt, um der Approximation der Kronenform Rechnung zu tragen.

Zur Evaluierung der Genauigkeit der berechneten CO₂-Bestände wurden die Berechnungsergebnisse mit den CO₂-Beständen der Erhebungsdaten, welche mit der gleichen Methodik berechnet wurden, verglichen.

Tabelle 2: Schwellenwerte der Einzelbaumerkennung nach Xu et. al. (2023).

Baumhöhe (m)	Stammdistanz (m)	Höhendifferenz (m)
<= 10	< 3	< 3
(10, 15]	< 4	< 3
(15, 25]	< 5	< 4
> 25	< 5	< 5

4 Ergebnisse

4.1 Genauigkeit der Einzelbaumerkennung

Eine Baumerkennung mittels der Fensterfunktion von Popescu und Wynne (2004) führt im Untersuchungsgebiet zu einer Übersegmentierung und es werden bei 1.683 Erhebungsbäumen 2.046 Bäume detektiert (siehe Tabelle 3). 900 der 2.046 detektierten Bäume konnten einem Erhebungsbaum zugeordnet werden, was in einer Precision von 44 % resultiert. Der Recall beläuft sich auf 53 %, es wurden 900 der 1.683 Erhebungsbäume korrekt detektiert. Die auf den neu berechneten Fensterfunktionen basierenden Modelle leiden dagegen unter einer Untersegmentierung. So wurden mit dem Modell basierend auf der Linearen Regression nur 1.115 Bäume (SVM 1139,

GAM 1152) detektiert. Die Modelle weisen daher verglichen mit dem auf der Fensterfunktion von Popescu und Wynne (2004) basierenden Modell eine höhere Precision und einen niedrigeren Recall auf. Insgesamt hat das Modell mit der Fensterfunktion von Popescu und Wynne mit einem F1-Score von 0,48 die höchste Modellgüte.

Tabelle 3: Vergleich der Einzelbaumerkennungsgenauigkeit zwischen den Fensterfunktionen von Popescu und Wynne (2004) und den aus den Erhebungsdaten hergeleiteten Fensterfunktionen.

Fensterfunktion	Accuracy	Precision	Recall	F1-Score
Popescu und Wynne (2004)	0,32	0,44	0,53	0,48
LR-Gesamt	0,26	0,52	0,35	0,42
SVR-Gesamt	0,26	0,51	0,35	0,42
GAM-Gesamt	0,26	0,51	0,35	0,42

4.2 Genauigkeit der Kronendetektion

Bei der Evaluation der Kronendetektion mittels IoU (Tabelle 4) ist das gleiche Verhalten wie bei der Einzelbaumerkennung zu erkennen. Das auf der Fensterfunktion von Popescu und Wynne (2004) basierende Modell weist eine niedrigere Precision und einen höheren Recall auf, da schlicht deutlich mehr Baumkronen detektiert wurden. Allerdings führt diese Übersegmentierung dazu, dass der IoU unter den zulässigen Schwellenwert fällt. Bei einer Erhebungsbaumkrone, welche z. B. in drei kleinere Baumkronen segmentiert wurde, erreicht keine der drei detektierten Baumkronen den IoU-Schwellenwert während bei der Einzelbaumerkennung zumindest einer der detektierten Bäume als korrekt detektiert eingestuft würde. Dies führt dazu, dass alle drei aus den Erhebungsdaten berechneten Fensterfunktionen mit einem F1-Score von 0,37 eine höhere Modellgüte aufweisen als das Referenzmodell.

Tabelle 4: Evaluation der Kronendetektion und Vergleich zwischen dem Referenzmodell, welches die Fensterfunktion von Popescu und Wynne (2004) verwendet und den drei aus den Erhebungsdaten errechneten Modellen.

Fensterfunktion	Accuracy	Precision	Recall	F1-Score
Popescu und Wynne (2004)	0,20	0,30	0,36	0,33
LR-Gesamt	0,23	0,46	0,31	0,37
SVR-Gesamt	0,23	0,46	0,31	0,37
GAM-Gesamt	0,23	0,46	0,31	0,37

4.3 CO₂ Bestände

Basierend auf der Methodik aus Kapitel 2.3 wurden die CO₂-Bestände berechnet. Den Referenzwert bilden die Erhebungsdaten. Die auf Basis des Kölner Baumkatasters berechneten CO₂-Beständen decken lediglich 8 % des Referenzbestandes ab. Im Vergleich hierzu schneiden sowohl das Referenzmodell, mit der Fensterfunktion von Popescu und Wynne (2004), als auch die drei neu entwickelten Modelle, welche auf den aus den Erhebungsdaten hergeleiteten Fensterfunktionen basieren, besser ab. Tabelle 5 zeigt stellvertretend die Ergebnisse der SVR-Modelle. Das Modell Popescu und Wynne erreicht einen CO₂-Bestand von 4.114 t, was einer Abweichung von 33 % vom Referenzwert entspricht. Besonders gut schneidet es, mit einer Abweichung von 2 %, auf Erholungsflächen ab. Schwächen zeigen sich insbesondere bei Bäumen auf Verkehrsflächen. Hier wird der CO₂-Bestand um 249 % überschätzt. Im Vergleich hierzu überschätzt das Modell SVR-Gesamt den CO₂-Bestand auf Verkehrsflächen um 162 % und unterschätzt ihn auf Erholungsflächen um 7 %. Im gesamten Untersuchungsgebiet ergibt sich ein CO₂-Bestand von 3.642 t, was einer Abweichung von 17 % entspricht. Somit konnte die Genauigkeit der CO₂-Bestandsermittlung um 52 % verbessert werden. Bei den flächennutzungsartbezogenen Modellen zeigt sich keine signifikante Verbesserung im Vergleich zum SVR-Gesamt Modell.

Tabelle 5: Vergleich geschätzter CO₂-Bestände basierend auf den Erhebungsdaten, dem Baumkataster der Stadt Köln⁶, dem Referenzmodell Popescu und Wynne (2004) und aus den Erhebungsdaten mittels hergeleiteten Fensterfunktionen am Beispiel der SVR.

Datenbasis	CO ₂ Bestand							
	Verkehrsflächen		Freiflächen Wohnen		Erholungsflächen		Gesamt	
	t	%	t	%	t	%	t	%
Erhebungsdaten	233	100	1.497	100	1.009	100	3.103	100
Baumkataster Köln	185	80	44	3	13	1	246	8
Popescu und Wynne (2004)	813	349	1.868	125	1.028	102	4.114	133
SVR-Gesamt	611	262	1.725	115	943	93	36.42	117
SVR-GFW	598	257	1.729	115	1.018	101	3.695	119
SVR-VK	594	255	1.704	114	1.219	121	3.664	118
SVR-ERH	658	282	1.732	116	1.213	120	3.768	121

⁶ <https://offenedaten-koeln.de/dataset/baumkataster-koeln-2020> , abgerufen am 31.05.2024

5 Diskussion und Fazit

Aus den Ergebnissen wird ersichtlich, dass eine automatisierte Baumerkennung im Vergleich zum bestehenden Baumkataster eine deutliche Verbesserung der Datenerfassung herbeiführt, da dort nicht alle Bäume erfasst sind. Die in diesem Beitrag vorgestellten methodischen Erweiterungen konnten die Überschätzung des CO₂-Bestandes von 33% auf 17% zu reduzieren. Ein wesentlicher Kritikpunkt des Vorgehens ist die bisherige Evaluation der Modelle nur auf Trainingsdaten, wodurch die Generalisierbarkeit unklar bleibt. Die Übertragbarkeit auf andere Untersuchungsgebiete muss noch validiert werden, um die Anwendbarkeit umfassend zu beurteilen. Mit einer größeren Datenbasis könnten die Fensterfunktionen verbessert werden. Orte mit hoher Baumdichte werden stark untersegmentiert, da Bäume, welche sich unterhalb der Baumkrone eines anderen Baums befinden, in den untersuchten Daten nicht detektiert werden können. Abbildung 3 zeigt das Ergebnis am Beispiel eines Wohnblocks; im Vergleich dazu zeigt Abbildung 4 einen Fall von Untersegmentierung bei dichtem Baumbestand.



Abb. 3: Best-Fit mittels SVR-Gesamt am Beispiel eines Wohnblocks. Detektierte Kronenpolygone in Rot, Stammposition aus Erhebungsdaten in Weiß. Eigene Darstellung, DOP bereitgestellt von Geobasis NRW.




Abb. 4: Untersegmentierung bei dichtem Baumbestand. Detektierte Kronenpolygone in Rot, Stammposition aus Erhebungsdaten in Weiß. Eigene Darstellung, DOP bereitgestellt von Geobasis NRW.

Schlussfolgernd lässt sich festhalten, dass die Vegetationserkennung mit Fernerkundungsdaten etabliert ist, die urbane Baumkronenerkennung jedoch ein aktuelles Forschungsthema bleibt. An die Flächennutzungsart angepasste Ansätze versprechen eine verbesserte Erkennung und könnten datenbasierte Lösungen für das Management von blau-grünen Infrastrukturen in Städten fördern. Perspektivisch sollte das Ziel die Entwicklung und der Einsatz flächennutzungsspezifischer Fensterfunktionen sein, die eine bessere Übertragbarkeit für die automatisierte Baumkronenerkennung in Städten gewährleisten könnten.

6 Literaturverzeichnis

- Dalponte, Michele/Coomes, David A./Murrell, David (2016). Tree-centric mapping of forest carbon density from airborne laser scanning and hyperspectral data. <https://doi.org/10.1111/2041-210x.12575>.
- Gülçin, Derya/van den Bosch, Cecil C. Konijnendijk (2021). Assessment of Above-Ground Carbon Storage by Urban Trees Using LiDAR Data: The Case of a University Campus. <https://doi.org/10.3390/f12010062>.
- Heinzel, Johannes N./Weinacker, Holger/Koch, Barbara (2011). Prior-knowledge-based single-tree extraction. <https://doi.org/10.1080/01431161.2010.494633>.
- Jean-Romain Roussel/David Auty/Nicholas C. Coops/Piotr Tompalski/Tristan R.H. Goodbody/Andrew Sánchez Meador/Jean-François Bourdon/Florian de Boissieu/Alexis Achim (2020). lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. <https://doi.org/10.1016/j.rse.2020.112061>.
- Kändler, Gerald/Adler, P./Hellbach, A. (2011). Wie viel Kohlenstoff speichern Stadtbäume? Eine Fallstudie am Beispiel der Stadt Karlsruhe. (abgerufen am 11.09.2024).
- Li, Wenkai/Guo, Qinghua/Jakubowski, Marek K./Kelly, Maggi (2012). A New Method for Segmenting Individual Trees from the Lidar Point Cloud. <https://doi.org/10.14358/pers.78.1.75>.
- Limberger, Frederico A./Oliveira, Manuel M. (2015). Real-time detection of planar regions in unorganized point clouds. <https://doi.org/10.1016/j.patcog.2014.12.020>.
- Liu, Tao/Im Jungho/Quackenbush, Lindi J. (2015). A novel transferable individual tree crown delineation model based on Fishing Net Dragging and boundary classification. <https://doi.org/10.1016/j.isprsjprs.2015.10.002>.
- Münzinger, Markus/Prechtel, Nikolas/Behnisch, Martin (2022). Mapping the urban forest in detail: From LiDAR point clouds to 3D tree models. <https://doi.org/10.1016/j.ufug.2022.127637>.
- Naber, Elias/Volk, Rebekka/Mörmann, Kai/Boehnke, Denise/Lützkendorf, Thomas/Schultmann, Frank (2022). Namares—A Surface Inventory and Intervention Assessment Model for Urban Resource Management. <https://doi.org/10.3390/su14148485>.

- Ozdarici-Ok, Asli/Ok, Ali Ozgun (2023). Using remote sensing to identify individual tree species in orchards: A review. <https://doi.org/10.1016/j.scienta.2023.112333>.
- Ponce, Juan Manuel/Aquino, Arturo/Tejada, Diego/Al-Hadithi, Basil Mohammed/Andújar, José Manuel (2021). A Methodology for the Automated Delineation of Crop Tree Crowns from UAV-Based Aerial Imagery by Means of Morphological Image Analysis. <https://doi.org/10.3390/agronomy12010043>.
- Popescu, Sorin C./Wynne, Randolph H. (2004). Seeing the Trees in the Forest. <https://doi.org/10.14358/pers.70.5.589>.
- Sačkov, I./Hlásny, T./Bucha, T./Juriš, M. (2017). Integration of tree allometry rules to treetops detection and tree crowns delineation using airborne lidar data. <https://doi.org/10.3832/ifor2093-010>.
- Schmohl, Stefan/Vallejo, Alejandra Narváez/Soergel, Uwe (2022). Individual Tree Detection in Urban ALS Point Clouds with 3D Convolutional Networks. <https://doi.org/10.3390/rs14061317>.
- Silva, Carlos A./Hudak, Andrew T./Vierling, Lee A./Loudermilk, E. Louise/O'Brien, Joseph J./Hiers, J. Kevin/Jack, Steve B./Gonzalez-Benecke, Carlos/Lee, Heezin/Falkowski, Michael J./Khosravipour, Anahita (2016). Imputation of Individual Longleaf Pine (lessiLiDAR Data. <https://doi.org/10.1080/07038992.2016.1196582>.
- United Nations (2015). Transforming our world: The 2030 agenda for sustainable development.
- Volk, Rebekka/Rambhia, Mihir/Naber, Elias/Schultmann, Frank (2022). Urban Resource Assessment, Management, and Planning Tools for Land, Ecosystems, Urban Climate, Water, and Materials—A Review. <https://doi.org/10.3390/su14127203>.
- Weinstein, Ben G./Graves, Sarah J./Marconi, Sergio/Singh, Aditya/Zare, Alina/Stewart, Dylan/Bohlman, Stephanie A./White, Ethan P. (2021). A benchmark dataset for canopy crown detection and delineation in co-registered airborne RGB, LiDAR and hyperspectral imagery from the National Ecological Observation Network. <https://doi.org/10.1371/journal.pcbi.1009180>.
- Xu, Dandan/Wang, Haobin/Xu, Weixin/Luan, Zhaoqing/Xu, Xia (2021). LiDAR Applications to Estimate Forest Biomass at Individual Tree Scale: Opportunities, Challenges and Future Perspectives. <https://doi.org/10.3390/f12050550>.
- Xu, Xin/Iuricich, Federico/Floriani, Leila De (2023). A topology-based approach to individual tree segmentation from airborne LiDAR data. <https://doi.org/10.1007/s10707-023-00487-4>.
- Yang, Lin/Wu, Xiaqing/Praun, Emil/Ma, Xiaoxu (2009). Tree detection from aerial imagery. <https://doi.org/10.1145/1653771.1653792>.